

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky  
a komunikačních technologií

DIPLOMOVÁ PRÁCE



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

## ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

## KLASIFIKACE CÉV SÍTNICE

CLASSIFICATION OF RETINAL BLOOD VESSELS

### DIPLOMOVÁ PRÁCE

MASTER'S THESIS

### AUTOR PRÁCE

AUTHOR

Bc. Jana Mitrengová

### VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jan Odstrčilík, Ph.D.

BRNO 2021

# Diplomová práce

magisterský navazující studijní program **Biomedicínské inženýrství a bioinformatika**

Ústav biomedicínského inženýrství

**Studentka:** Bc. Jana Mitrengová

**ID:** 191462

**Ročník:** 2

**Akademický rok:** 2020/21

**NÁZEV TÉMATU:**

## Klasifikace cév sítnice

### POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s principem snímání očního pozadí pomocí experimentálního video oftalmoskopu a fundus kamery. 2) Proveďte literární rešerši prací zabývajících se klasifikací cév sítnice na tepny a žíly. 3) Navrhněte vhodnou metodu pro klasifikaci cévního řečiště a realizujte ji v programovém prostředí MATLAB. 4) Proveďte vyhodnocení úspěšnosti klasifikace na zadaných obrazových datech. 5) Navrhněte a implementujte vhodný přístup pro analýzu pulzací cévního řečiště v předem definované oblasti zájmu. 6) Proveďte diskusi dosažených výsledků a zhodnoťte účinnost a využitelnost aplikovaného řešení. 7) Vytvořené programové funkce přehledně okomentujte.

### DOPORUČENÁ LITERATURA:

[1] TORNOW, R.; ODSTRČILÍK, J.; KOLÁŘ, R. Time-resolved quantitative inter-eye comparison of cardiac cycle-induced blood volume changes in the human retina. *Biomedical Optics Express*, 2018, roč. 9, č. 12, s. 6237-6254. ISSN: 2156-7085.

[2] MIRI, M.; AMINI, Z.; RABBANI, H. et al. A Comprehensive Study of Retinal Vessel Classification Methods in Fundus Images. *J Med Signals Sens*, 2017, roč. 7, č. 2, s. 59-70.

**Termín zadání:** 8.2.2021

**Termín odevzdání:** 21.5.2021

**Vedoucí práce:** Ing. Jan Odstrčilík, Ph.D.

**prof. Ing. Ivo Provazník, Ph.D.**  
předseda rady studijního programu

### UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

## ABSTRAKT

Práce se zabývá klasifikací cévního řečiště v obrazových datech sítnice. První část práce pojednává o anatomii oka a zaměřuje se na popis sítnice a jejího cévního zásobení. Dále je popsán princip fundus kamery a experimentálního video oftalmoskopu. Druhá část práce je věnována literární rešerši odborných prací, které se zabývají problematikou klasifikace retinálních cév na tepny a žíly. Následně je uveden princip vybraných metod strojového učení. Na základě prostudovaných odborných publikací byly sestaveny dva návrhy metod pro klasifikaci cévního řečiště, první s využitím SVM klasifikátoru a druhá s využitím konvoluční neuronové sítě U-Net. Na závěr proběhla analýza pulzací cévního řečiště. Praktická část práce byla realizována v programovacím prostředí Matlab, přičemž pro klasifikaci byly použity snímky z RITE, IOSTAR a AFIO databáze, a při analýze pulzací byly zpracovány videosekvence sítnice pořízené experimentálním video oftalmoskopem.

## KLÍČOVÁ SLOVA

sítnice, cévní řečiště sítnice, klasifikace, metoda podpůrných vektorů, konvoluční neuronové sítě, U-Net, pulzace

## ABSTRACT

The thesis deals with the classification of the retinal blood vessels in retinal image data. The first part of the thesis deals with the anatomy of the human eye and focuses on the description of the retina and its blood circulation. It further describes the principle of fundus camera and experimental video ophthalmoscope. The second part of the thesis is devoted to a literature search of academic publications that deal with the classification of the retinal vessels into arteries and veins. Subsequently, the principle of selected machine learning methods is presented. Based on the literature research, two methods for the classification of the blood vessels were proposed, the first one using the SVM classifier and the second one using the convolutional neural network U-Net. At the end, the analysis of vascular pulsations was performed. The practical part of the thesis was carried out in Matlab programming interface and images from the RITE, IOSTAR and AFIO database were used for classification and the retinal video sequences taken with an experimental video ophthalmoscope were processed in the analysis of pulsations.

## KEYWORDS

retina, blood vessels of retina, classification, support vector machines, convolutional neural network, U-Net, pulsation

MITRENGOVÁ, Jana. *Klasifikace cév sítnice*. Brno, 2021, 80 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce: Ing. Jan Odstrčilík, Ph.D.



## PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma „Klasifikace cév sítnice“ jsem vypracovala samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autorka uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědoma následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno .....

.....

podpis autorky

## PODĚKOVÁNÍ

Ráda bych poděkovala vedoucímu diplomové práce panu Ing. Janu Odstrčilíkovi, Ph.D. především za jeho věnovaný čas, za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

# Obsah

<b>Úvod</b>	<b>12</b>
<b>1 Oko</b>	<b>13</b>
1.1 Anatomie oka . . . . .	13
1.2 Sítňice . . . . .	14
1.2.1 Stavba sítňice . . . . .	14
1.2.2 Cévní zásobení sítňice . . . . .	14
1.2.3 Vlastnosti cév sítňice . . . . .	15
<b>2 Snímání očního pozadí</b>	<b>16</b>
2.1 Fundus kamera . . . . .	16
2.2 Experimentální video oftalmoskop . . . . .	18
<b>3 Rešerše prací zabývajících se klasifikací cév sítňice</b>	<b>20</b>
3.1 Poloautomatické metody . . . . .	20
3.2 Automatické metody . . . . .	21
<b>4 Klasifikace cévního řečiště</b>	
<b>s využitím metod strojového učení</b>	<b>25</b>
4.1 Strojové učení . . . . .	25
4.2 Klasifikační algoritmy . . . . .	25
4.2.1 SVM klasifikátor . . . . .	25
4.3 Umělé neuronové sítě . . . . .	27
4.4 Hluboké učení . . . . .	27
4.4.1 Konvoluční neuronové sítě . . . . .	28
4.4.2 U-Net . . . . .	29
<b>5 Návrh a realizace metod pro klasifikaci cévního řečiště</b>	<b>30</b>
5.1 Použitá data . . . . .	30
5.1.1 RITE dataset . . . . .	30
5.1.2 IOSTAR dataset . . . . .	31
5.1.3 AFIO dataset . . . . .	32
5.2 Příprava dat pro klasifikaci cévního řečiště . . . . .	33
5.3 Klasifikace cévního řečiště s využitím	
SVM klasifikátoru . . . . .	34
5.3.1 Předzpracování snímků sítňice . . . . .	35
5.3.2 Detekce středu optického disku a vymezení oblasti zájmu kla-	
sifikace . . . . .	36

5.3.3	Extrakce příznaků . . . . .	38
5.3.4	Klasifikace . . . . .	42
5.4	Klasifikace cévního řečiště s využitím konvoluční neuronové sítě U-Net	43
5.4.1	Předzpracování dat . . . . .	43
5.4.2	Trénování sítě . . . . .	43
<b>6</b>	<b>Výsledky klasifikace</b>	<b>47</b>
6.1	Matice záměn . . . . .	47
6.2	Výsledek klasifikace cévního řečiště s využitím SVM klasifikátoru . .	49
6.2.1	Klasifikace cév v oblasti zájmu okolo optického disku . . . . .	49
6.2.2	Klasifikace cév v celém snímku sítnice . . . . .	52
6.2.3	Shrnutí výsledku klasifikace s využitím SVM klasifikátoru . .	55
6.3	Výsledek klasifikace cévního řečiště s využitím konvoluční neuronové sítě U-Net . . . . .	55
6.3.1	Srovnání klasifikace cév s využitím SVM klasifikátoru a konvoluční neuronové sítě U-Net . . . . .	62
<b>7</b>	<b>Analýza pulzací cévního řečiště</b>	<b>63</b>
7.1	Použitá data . . . . .	63
7.2	Návrh metody pro analýzu pulzací . . . . .	64
7.3	Vymezení oblasti zájmu analýzy . . . . .	64
7.4	Klasifikace cév . . . . .	65
7.5	Analýza pulzací cév . . . . .	66
	<b>Závěr</b>	<b>72</b>
	<b>Literatura</b>	<b>74</b>
	<b>Seznam symbolů, veličin a zkratk</b>	<b>79</b>
<b>A</b>	<b>Přílohy</b>	<b>80</b>

# Seznam obrázků

1.1	Anatomie oka . . . . .	13
2.1	Snímek očního pozadí zachycený fundus kamerou . . . . .	16
2.2	Zprůměrovaný snímek očního pozadí z videosekvence zachycené experimentálním video oftalmoskopem . . . . .	19
4.1	Grafické znázornění principu lineárního SVM klasifikátoru na příkladu klasifikace dat do dvou lineárně separabilních tříd . . . . .	26
4.2	Grafické srovnání jednoduché umělé neuronové sítě a umělé neuronové sítě hlubokého učení . . . . .	27
4.3	U-Net architektura . . . . .	29
5.1	Příklad dat z RITE datasetu. Snímek očního pozadí, maska segmentovaných cév a obraz klasifikovaných cév (zleva). . . . .	31
5.2	Příklad dat z IOSTAR datasetu. Snímek očního pozadí, maska segmentovaných cév a obraz klasifikovaných cév (zleva). . . . .	31
5.3	Příklad dat z IOSTAR datasetu. Masky zorného pole a masky optického disku (zleva). . . . .	32
5.4	Příklad dat z AFIO datasetu. Snímek očního pozadí, maska segmentovaných cév a obraz očního pozadí doplněný o klasifikované cévy (zleva). . . . .	32
5.5	Vývojový diagram klasifikace cév sítnice . . . . .	34
5.6	Červený, zelený a modrý kanál snímku v RGB prostoru (zleva) . . . .	35
5.7	Originální snímek a jeho úprava adaptivní ekvalizací histogramu (zleva)	35
5.8	Eliminace cév ve snímku a zadání počátečních bodů kontury (zleva) .	36
5.9	Binární maska oblasti zájmu okolo optického disku . . . . .	37
5.10	Skeleton cévního řečiště a výsledek jeho vynásobení s binární maskou oblasti zájmu (zleva) . . . . .	37
5.11	Boxploty dvou vybraných příznaků . . . . .	40
5.12	Boxplot distanční matice centrálních pixelů cévy boxplot průměrné hodnoty jasu pixelů (zleva) . . . . .	41
5.13	Boxplot průměrné intenzity centrálních pixelů v červeném kanálu RGB prostoru a boxplot průměrné intenzity centrálních pixelů v zeleném kanálu RGB prostoru (zleva) . . . . .	41
5.14	Boxplot intenzity pixelů po aplikaci 2D Gaussova filtru s hodnotou směrodatné odchylky 2 v modrém kanálu RGB prostoru a boxplot intenzity pixelů po aplikaci 2D Gaussova filtru s hodnotou směrodatné odchylky 4 v zeleném kanálu RGB prostoru (zleva) . . . . .	42
5.15	Průběh trénování sítě s hodnotami vah 0,6 pro pozadí, 17 pro tepny a 14 pro žíly . . . . .	45

5.16	Průběh trénování sítě s hodnotami vah 0,7 pro pozadí, 18 pro tepny a 14 pro žíly . . . . .	46
6.1	Matice záměn . . . . .	47
6.2	Výsledná matice záměn klasifikace cév ležících v oblasti zájmu okolo OD	49
6.3	Výsledek klasifikace cév snímku 1 a odpovídající ground truth obraz (zleva) . . . . .	50
6.4	Výsledná matice záměn klasifikace cév snímku 1 . . . . .	50
6.5	Výsledek klasifikace cév snímku 2 a odpovídající ground truth obraz (zleva) . . . . .	51
6.6	Výsledná matice záměn klasifikace cév snímku 2 . . . . .	51
6.7	Výsledná matice záměn klasifikace cév v celém snímku sítnice . . . .	52
6.8	Výsledek klasifikace cév snímku 1 a odpovídající ground truth obraz (zleva) . . . . .	53
6.9	Výsledná matice záměn klasifikace cév v celém snímku 1 . . . . .	53
6.10	Výsledek klasifikace cév snímku 2 a odpovídající ground truth obraz (zleva) . . . . .	54
6.11	Výsledná matice záměn klasifikace cév v celém snímku 2 . . . . .	54
6.12	Výsledná matice záměn klasifikace cév a její normalizovaná verze (zleva). Zobrazeny výsledky neuronové sítě s váhami 0,6 pro pozadí, 17 pro tepny a 14 pro žíly. . . . .	56
6.13	Výsledná matice záměn klasifikace cév a její normalizovaná verze (zleva). Zobrazeny výsledky neuronové sítě s váhami 0,7 pro pozadí, 18 pro tepny a 14 pro žíly. . . . .	56
6.14	Výsledek klasifikace cév na výstupu první neuronové sítě (váhy 0,6 pro pozadí, 17 pro tepny, 14 pro žíly) (vlevo), výsledek klasifikace cév na výstupu druhé neuronové sítě (váhy 0,7 pro pozadí, 18 pro tepny, 14 pro žíly) (uprostřed) a ground truth obraz klasifikovaného snímku (vpravo) . . . . .	58
6.15	Výsledná matice záměn klasifikace cév první neuronové sítě (váhy 0,6 pro pozadí, 17 pro tepny, 14 pro žíly) (vlevo) a druhé neuronové sítě (váhy 0,7 pro pozadí, 18 pro tepny, 14 pro žíly) (vpravo) . . . . .	58
6.16	Výsledek klasifikace cév na výstupu první neuronové sítě vynásobený se segmentační maskou cév (váhy 0,6 pro pozadí, 17 pro tepny, 14 pro žíly) (vlevo), výsledek klasifikace cév na výstupu druhé neuronové sítě vynásobený se segmentační maskou cév (váhy 0,7 pro pozadí, 18 pro tepny, 14 pro žíly) (uprostřed) a ground truth obraz klasifikova- ného snímku (vpravo) . . . . .	59

6.17	Výsledné matice záměn klasifikace cév první neuronové sítě (váhy 0,6 pro pozadí, 17 pro tepny, 14 pro žíly) (vlevo) a druhé neuronové sítě (váhy 0,7 pro pozadí, 18 pro tepny, 14 pro žíly) (vpravo) po vynásobení se segmentační maskou cév . . . . .	59
6.18	Výsledek klasifikace cév na výstupu první neuronové sítě (váhy 0,6 pro pozadí, 17 pro tepny, 14 pro žíly) (vlevo), výsledek klasifikace po vynásobení se segmentační maskou cév (uprostřed) a ground truth obraz klasifikovaného snímku (vpravo) . . . . .	60
6.19	Výsledná matice záměn klasifikace cév první neuronové sítě (váhy 0,6 pro pozadí, 17 pro tepny, 14 pro žíly) (vlevo) a výsledná matice záměn po vynásobení výsledku klasifikace se segmentační maskou cév (vpravo)	60
6.20	Výsledek klasifikace cév na výstupu druhé neuronové sítě (váhy 0,7 pro pozadí, 18 pro tepny, 14 pro žíly) (vlevo), výsledek klasifikace po vynásobení se segmentační maskou cév (uprostřed) a ground truth obraz klasifikovaného snímku (vpravo) . . . . .	61
6.21	Výsledná matice záměn klasifikace cév druhé neuronové sítě (váhy 0,7 pro pozadí, 18 pro tepny, 14 pro žíly) (vlevo) a výsledná matice záměn po vynásobení výsledku klasifikace se segmentační maskou cév (vpravo) . . . . .	61
7.1	Zprůměrovaný snímek z videosekvence získané video oftalmoskopem a odpovídající RGB snímek sítnice nasnímaný fundus kamerou (zleva)	63
7.2	Maska segmentovaných cév a obraz s klasifikovanými cévami (zleva)	63
7.3	Střed optického disku a kruhová oblast zájmu okolo OD (zleva)	64
7.4	Výsledek klasifikace cév a odpovídající ground truth obraz (zleva)	65
7.5	Výsledek klasifikace cév a odpovídající ground truth obraz (zleva)	65
7.6	Matice záměn pro klasifikaci cév . . . . .	66
7.7	Přiřazení numerické hodnoty úsekům cév . . . . .	67
7.8	Průměrné intenzity pixelů žíly . . . . .	67
7.9	Obálka průměrných intenzit pixelů žíly . . . . .	68
7.10	Porovnání průměrných intenzit pixelů tepny a žíly 1 . . . . .	68
7.11	Porovnání průměrných intenzit pixelů tepny a žíly 2 . . . . .	69
7.12	Porovnání průměrných intenzit pixelů tepny a žíly 3 . . . . .	70
7.13	Porovnání průměrných intenzit pixelů tepny na temporální a nazální straně sítnice . . . . .	71
7.14	Porovnání průměrných intenzit pixelů žíly na temporální a nazální straně sítnice . . . . .	71

# Seznam tabulek

6.1	Shrnutí výsledku klasifikace s využitím SVM klasifikátoru . . . . .	55
6.2	Shrnutí výsledku klasifikace s využitím neuronových sítí U-Net . . . .	57
6.3	Shrnutí výsledku klasifikace s využitím neuronových sítí, hodnoty po vynásobení klasifikovaných obrazů se segmentačními maskami . .	57
6.4	Shrnutí výsledku klasifikace s využitím SVM klasifikátoru a konvo- lučních neuronových sítí . . . . .	62



# Úvod

Klasifikace retinálních cév na tepny a žíly je v oblasti výzkumu stále aktuálním tématem. Některá onemocnění, jako je srdeční příhoda, hypertenze, cukrovka či další kardiovaskulární choroby, mohou ovlivnit strukturu cév sítnice a takové změny lze pozorovat na snímcích očního pozadí. Přesná klasifikace retinálních cév je nezbytná pro výpočet arterio-venózního poměru, který kvantifikuje závažnost kardiovaskulárních onemocnění. Díky digitálnímu zpracování obrazu sítnice a analýzy retinálních cév lze patologické stavy včas diagnostikovat a zahájit jejich léčbu.

Pro správnou klasifikaci cévního řečiště je potřeba znát anatomii oka a především stavbu sítnice a její cévní zásobení, které je popsáno v kapitole 1. Princip zobrazovacích systémů, kterými lze nasnímat vyšetřované oční pozadí je nastíněn v kapitole 2. Těmito zobrazovacími systémy jsou získána data, která jsou v této práci zpracovávána.

V kapitole 3 je vypracována literární rešerše odborných publikací, které se zabývají klasifikací cév sítnice a popisují v nich postupy jimi navržených metod pro co nejpřesnější klasifikaci cév na tepny a žíly. Na základě prostudovaných publikací byly navrženy dvě metody klasifikace cév, kterým je věnována praktická část práce.

V poslední teoretické kapitole 4 jsou popsány vybrané metody strojového učení.

Praktická část práce popisuje návrh metod, které jsou následně realizovány v programovacím prostředí Matlab. Návrh a realizace metod jsou představeny v kapitole 5. Pro klasifikaci cév sítnice byla zvolena metoda podpůrných vektorů a konvoluční neuronová síť U-Net, přičemž obě tyto metody strojového učení jsou metodami využívající učení s učitelem. Trénování klasifikátorů je tedy realizováno na trénovacích datech, ke kterým je přiřazena hodnota třídy, do které budou data klasifikována.

Natrénovaný klasifikátor SVM a konvoluční neuronová síť U-Net byly otestovány na testovací sadě dat, přičemž výsledné hodnoty úspěšnosti klasifikace jsou uvedeny v kapitole 6.

Závěrečná kapitola 7 je věnována analýze pulzací klasifikovaného cévního řečiště, ve které byly zpracovávány videosekvence sítnice nasnímané experimentálním video oftalmoskopem.

# 1 Oko


K nejsložitějším a nejdůležitějším smyslům lidského těla patří zrak, díky kterému se člověk dokáže orientovat v prostoru a vnímat světlo či barvy. Smyslovým párovým orgánem zraku je oko, které je tvořeno oční koulí a přídatnými očními orgány [1].

## 1.1 Anatomie oka

Oční koule je uložena v očníci a je složena ze tří vrstev, viz Obr. 1.1. První z nich je zevní vazivová vrstva tvořící tuhý a pevný obal oční koule. Vazivová vrstva zahrnuje bělimu a rohovku. Střední vrstva oční koule je nazývána živnatkou, přičemž je tato vrstva ve své zadní části tvořena cévnatkou a směrem do přední části oka je vrstva složena z řasnatého tělesa a duhovky. Poslední vnitřní nervová vrstva oční koule je tvořena sítnicí. [1, 2].

Obsah oční koule zahrnuje sklivec, před kterým je uložena čočka a přední i zadní oční komora jsou vyplněny komorovým mokem [1, 2].

Mezi přídatné oční orgány se řadí okohybné svaly zajišťující pohyb oční koule a patří k nim i zdvihač horního víčka. Dalšími přídatnými orgány oka jsou vazivový aparát očníce, víčka, slzné ústrojí a spojivka, což je tenká blána spojující přední plochu oční koule s víčky [1, 2].



Obr. 1.1: Anatomie oka [3]

## 1.2 Sítnice

Sítnice je tenká vnitřní vrstva oční koule s tloušťkou v rozmezí 0,1 – 0,5 mm. Rozlišují se dvě části sítnice, optická a slepá, kdy jsou tyto části od sebe odděleny čarou nazývanou ora serrata [1, 4].

### 1.2.1 Stavba sítnice

Optická část sítnice přiléhá na cévnatku. Tato část má při oftalmoskopickém vyšetření oranžovou až červenou barvu, a to právě díky prosvítání cév cévnatky. V optické části sítnice se nachází žlutá skvrna, v jejímž středu je prohlubeň fovea centralis známá jako místo nejostřejšího vidění, jelikož se do ní promítá centrální paprsek. Toto místo má při oftalmoskopickém vyšetření sytě červenou barvu [1].

Mediálně od žluté skvrny odstupuje z oční koule zrakový nerv, přičemž výstup nervu je označován jako optický disk. Místo neobsahuje žádné světločivné buňky a jedná se tedy o fyziologickou slepou skvrnu [1].

Stavbu sítnice lze pro zjednodušení dělit na zevní a vnitřní vrstvu. Zevní vrstvu tvoří jednovrstevný epitel, který společně s pigmentovanou vrstvou cévnatky vytváří světelnou izolační vrstvu pohlcující dopadající světelné paprsky, čímž zabraňuje jejich odrazu uvnitř oka. Do retinálního pigmentového epitelu jsou zanořeny zevní segmenty smyslových buněk a zastává důležitou roli v regeneraci fotoreceptorů [1, 4].

Vnitřní vrstva sítnice obsahuje smyslové buňky a neurony sbírající informace z fotoreceptorů a odvádějící je prostřednictvím zrakového nervu do mozku. Smyslových buněk jsou dva druhy, tyčinky a čípky. Tyčinky slouží k vnímání množství dopadajícího světla, zatímco čípky poskytují zrakovou ostrost a barevné vidění [1, 4].

Slepá část sítnice, označována jako pigmentový list řasnatého tělesa a duhovky, překrývá vnitřní plochu řasnatého tělesa a duhovky. Tato část sítnice je tvořena pouze pigmentovou vrstvou a neobsahuje žádné smyslové buňky [1].

### 1.2.2 Cévní zásobení sítnice

Výživu sítnice zajišťují retinální a choroidální cévy pocházející z první větve vnitřní karotické arterie. Retinální cévy zásobují vnitřní vrstvu sítnice a zevní vrstva je vyživována difuzí z choriokapilaris, jelikož se ve vrstvě nevyskytují cévy [4].

Centrální retinální arterie se po výstupu z papily zrakového nervu dělí na horní a dolní arterie a ty se následně dělí na nazální a temporální větve. Po prvním dělení arterií dojde ke ztrátě elastických vláken a vnitřní elastické membrány, a stanou se z nich arterioly. Zatímco arterie a vény probíhají ve vrstvě nervových vláken, arterioly a venuly prostupují do hlubších vrstev a vytvářejí hlavní mikrovaskulární síť [4].

V okolí terče zrakového nervu je kapilární síť složena až ze 4 vrstev a směrem k periférii se síť ztenčuje. Na nejzazší periférii sítnice a ve fovee centralis se kapiláry nevyskytují [4].

### 1.2.3 Vlastnosti cév sítnice

Cévy sítnice se vyznačují několika vlastnostmi, kterými lze tepny a žíly od sebe odlišit. Tepny jsou jasně červené barvy díky přítomnosti okysličené krve a na jejich silnějších stěnách lze zřetelně pozorovat světlý pruh, tzv. centrální reflex. Žíly jsou tmavší barvy a ve srovnání s tepnami jsou širší. Další charakteristikou sítnicových cév je to, že v okolí optického disku se tepny a žíly střídají (tedy jedna tepna sousedí s dvěma žilami a naopak), než dojde k jejich rozvětvení do periférií [5, 6].

V mnoha případech však tyto rozdíly ke správné klasifikaci cév nestačí. Snímek očního pozadí pořízený fundus kamerou může být nízké kvality a centrální reflex nebude dobře viditelný. Dále může nastat efekt stínění díky nehomogennímu osvětlení obrazu a cévy budou ve vnějších částech obrazu velmi tmavé. V tomto případě se tepny i žíly podobají, což vede k jejich nesprávné klasifikaci. Tloušťka cév se při klasifikaci také moc neuplatní, jelikož je v různých částech snímku proměnlivá. V nejbližší vzdálenosti od optického disku je tloušťka cév největší, naopak v periférii obrazu je jejich tloušťka nejmenší [5, 6].

#### Arterio-venózní poměr


Arterio-venózní poměr (AVR, z angl. Arterio-Venous Ratio) kvantifikuje závažnost kardiovaskulárních onemocnění. Pro získání hodnoty AVR je potřeba výpočet průměrné šířky retinálních tepen a retinálních žil v okolí optického disku, konkrétně v oblasti v rozmezí 0,5 – 1 průměru optického disku od jeho okraje. Fyziologická hodnota AVR je 2:3 a jakákoliv odchylka od této hodnoty může poukazovat na patologický stav [5, 7].

## 2 Snímání očního pozadí

Vyšetření očního pozadí (fundu) patří k nejzákladnějším oftalmoskopickým vyšetřením. Díky zobrazení zadního segmentu oka lze pozorovat stav sítnice, žluté skvrny, zřetelného nervu či cév, a tím sledovat případné patologie, tedy například glaukom, diabetickou retinopatii, okluzi sítnicové žíly a další [8].

### 2.1 Fundus kamera

Fundus kamera je primárně určena pro snímání sítnice a výsledek měření je získán v digitální podobě. Příklad snímku očního pozadí pořízeného fundus kamerou je zobrazen na Obr. 2.1. Na barevném snímku lze pozorovat optický disk, cévy sítnice a žlutou skvrnu.



Obr. 2.1: Snímek očního pozadí zachycený fundus kamerou

Přístroj sestává ze dvou hlavních částí, z osvětlovacího a pozorovacího systému.

Osvětlovací systém je tvořen systémem kruhových clon, kdy světelný svazek paprsků prochází osvětlovací čočkou a otvorem v zrcadle. Podle druhu osvětlení lze fundus kamery rozdělit na mydriatické, využívající k osvětlení viditelné halogenové světlo, a non-mydriatické, které osvětlují infračerveným světlem [8].

Princip pozorovacího systému vychází z metody nepřímé oftalmoskopie. Čočka objektivu vytvoří skutečný obraz osvětleného fundu v rovině otvoru zrcadla, za kterým se vytvoří druhý obraz zprostředkovaný hlavní čočkou objektivu, a za pomoci

posuvné kolimátorové čočky se jeví obraz v nekonečnu. Díky tomuto systému lze docílit vysokého rozlišení snímaného obrazu, možnosti nastavení infračerveného osvětlení u CCD kamery a přesnějšího zaměření projekčního zařízení [8].

Velikost zorného pole fundus kamer lze nastavit v rozmezí 20° až 50° pomocí měnitelné clony. Je také možné sestavit panoramatický snímek pro současné hodnocení centrální i periferní sítnice, kdy se pacient bude dívat do různých směrů. Pro jiná zobrazení lze použít přídatné speciální kontaktní čočky či širokoúhlé pozorovací čočky [8].

Kamera přístroje pracuje na základě diagnostických možností v různých režimech nastavení, jsou jimi:

- monochromatické zobrazení,
- fluorescenční angiografie,
- autofluorescence fundu,
- stereoskopické zobrazení,
- modul širokého zorného pole.

### **Monochromatické zobrazení**

Monochromatické zobrazení umožňuje filtraci světla různých vlnových délek za účelem zvýraznění jednotlivých struktur. V případě použití zeleného filtru dojde ke zvýraznění kontrastu cévního zásobení sítnice. Zelené světlo je totiž silně pohlcováno hemoglobinem a cévy se budou jevit jako tmavé. Modrým filtrem se zvýrazní vrstva nervových vláken sítnice díky její vlastnosti rozptylovat světlo. Jako poslední je červený filtr sloužící pro snímání cévnatky, červené světlo je totiž slabě pohlcováno pigmentovým epitelem a do tkáně pronikne hlouběji [8].

### **Fluorescenční angiografie**

Díky fluorescenční angiografii jsou zobrazeny cévy krevního řečiště sítnice a cévnatka s vysokým kontrastem. Díky tomu lze měřit dynamiku průtoku krve za účelem detekce blokády či krvácení. Před vyšetřením je pacientovi intravenózně podána dávka fluorescenčního barviva, které je excitováno monochromatickým světlem s vysokým koeficientem absorpce. Jako barvivo je využíván buď fluorid sodný, anebo indocyani nová zeleň. Výstupem fluorescenční angiografie je černobílý snímek s jasnými místy představující silnou fluorescenci, což nasvědčuje o průsaku cév, defektech sítnicového pigmentového epitelu a edému. Jestliže je fluorescence na výsledném snímku slabá, může se jednat o okluzi cévy [8].

### **Autofluorescence fundu**

Autofluorescence fundu je metoda umožňující topografické znázornění rozložení pigmentů, metabolitů či podobných substancí. Díky této metodě lze zjistit funkční stav sítnice na buněčné úrovni [8].

## Stereoskopické zobrazení

Stereoskopické zobrazení umožňuje prostorový pohled na oční pozadí a papilu zrakového nervu. Pro stereoskopické zobrazení se využívá různých konstrukcí přístroje, lze snímat se dvěma speciálními stereo fundus kamerami nebo s jednou sekvenci monokulární kamerou [8].


## 2.2 Experimentální video oftalmoskop

Pro co nejpřesnější srovnání rychlých dynamických změn v tkáni sítnice je potřeba snímat pozadí obou očí zároveň. Případné patologické odchylky u takto paralelně nasnímaných fundů v čase mohou být klíčové pro včasné odhalení očních onemocnění [9, 10].

Experimentální non-mydriatický video oftalmoskop je navržen tak, aby byl schopen snímat oční pozadí obou očí současně, přičemž je založen na stejném principu jako fundus kamera. Oftalmoskopická čočka vytvoří snímek sítnice v obrazové rovině a takový obraz je poté zobrazen systémem achromatických čoček na snímač CCD kamery. Snímač kamery je propojen pomocí USB kabelu s počítačem, který slouží pro sběr nasnímaných dat. USB rozhraní je také použito pro napájení video oftalmoskopu. Jako zdroj světla je použita jednoduchá světlená dioda o vlnové délce 575 nm. Příslušná vlnová délka je zvolena za účelem co nejlepšího kontrastu snímků pro malé změny objemu krve v cévách [9, 10, 11].

Hlavní rozdíl mezi video oftalmoskopem a fundus kamerou je dráha osvětlení očního pozadí. Experimentální video oftalmoskop využívá pro osvětlení centrální oblast zornice, přičemž odražené paprsky jsou snímány prostřednictvím okraje zornice. Stejně je tomu v případě skenovacích laserových oftalmoskopů [9].

Nevýhodou experimentálního video oftalmoskopu je přítomnost šumu ve výsledných snímcích díky nízké hodnotě intenzity osvětlení sítnice. Snímky z videosekvence jsou v odstínech šedi a některé mohou obsahovat světelné artefakty kruhového tvaru, viz Obr. 2.2.



Obr. 2.2: Zprůměrovaný snímek očního pozadí z videosekvence zachycené experimentálním video oftalmoskopem



## 3 Rešerše prací zabývajících se klasifikací cév sítnice

Klasifikace retinálních cév na tepny a žíly je v oblasti výzkumu stále aktuálním tématem. Některá onemocnění, jako je srdeční příhoda, hypertenze, cukrovka či další kardiovaskulární choroby, mohou ovlivnit strukturu cév sítnice a takové změny lze sledovat na snímcích očního pozadí. Přesná klasifikace retinálních cév je nezbytná pro výpočet hodnoty AVR a jen malé chyby v klasifikaci mohou vést k velkým chybám při finálním výpočtu tohoto poměru. Díky digitálnímu zpracování obrazu sítnice a analýzy retinálních cév lze výše zmíněná onemocnění včas diagnostikovat a zahájit jejich léčbu [5].

Proces výpočtu hodnoty AVR zahrnuje několik kroků. Nejprve je žádoucí vhodné předzpracování snímku sítnice. Následuje segmentace cév a detekce optického disku za účelem vymezení oblasti zájmu klasifikace. Ze segmentovaných cév se následně extrahují příznaky, které slouží pro samotnou klasifikaci cév na tepny a žíly. Na závěr je měřena šířka tepen a žil.

Metody klasifikace cév mohou být poloautomatické nebo plně automatické. Poloautomatické metody jsou založeny na ručním označení cévy expertem v jejím počátku za tepnu nebo žílu. Následně se s využitím sledování strukturní charakteristiky či konektivity cévy klasifikuje zbytek vaskulární sítě sítnice. Pro automatickou klasifikaci jsou nejprve ze segmentovaného obrazu získány pixely středové linie cévy, které tvoří její kostru. Následně jsou extrahovány různé příznaky pro každý pixel středové linie (anebo pro profil či segment cévy). Na základě extrahovaných příznaků je každý pixel označen klasifikátorem jako tepna či žíla [5].

V následujícím textu jsou zmíněny vybrané práce zabývající se klasifikací cévního řečiště.

### 3.1 Poloautomatické metody

Martinez-Perez M. E. a kol. [12] roku 2002 představili poloautomatickou metodu, ve které jsou samostatně analyzovány arteriální a venózní stromy. Operátor nejprve vybral strom, který měl být analyzován a označil jej buď za arteriální, anebo venózní. Následně byla na tomto stromě provedena analýza jeho geometrických vlastností. Na základě získaných hodnot byla počítána hodnota AVR.

## 3.2 Automatické metody

Grisan E. a Ruggeri A. [13] vyvinuli v roce 2003 algoritmus klasifikace cév s využitím přístupu divide et impera, kdy je soustředná zóna kolem optického disku rozdělena na kvadranty, ve kterých byla provedena důkladnější lokální klasifikační analýza. Metoda také předpokládá, že v každém kvadrantu je podobný počet žil a tepen a jsou na nich dobře pozorovatelné rozdíly v jejich vlastnostech.

Extrakce příznaků cév byla provedena v závislosti na jejich rozdílném odstínu barvy v červeném kanálu a následně byly cévy klasifikovány s využitím fuzzy shlukování. Nejprve proběhla klasifikace cévy v určené zóně kolem optického disku a poté byla rozšířena i na oblast mimo tuto zónu, ve které je rozlišení cév na tepny a žíly náročnější.

Výsledky této metody dosahovaly celkové chyby 12 %. Jestliže se braly v úvahu jen diagnosticky důležité cévy sítnice, došlo ke snížení chyby na 7 %.

Niemeijer M. a kol. [14] představili v roce 2009 automatickou metodu klasifikace retinálních cév. Ze segmentovaných cév byly nejprve extrahovány pixely jejich středových linií a z vytvořené vaskulární kostry byly odstraněny bifurkace a body křížení, tedy byly vynechány ty pixely, které sousedily s více než dvěma pixely. Tyto operace rozdělily vaskulární síť do jednotlivých segmentů cév, kdy segmenty, které měly délku menší než čtyři pixely, byly odstraněny. Následně byly z každého pixelu cévy extrahovány příznaky a na jejich základě byla každému pixelu přiřazena pravděpodobnost, že je klasifikován jako žíla.

V práci bylo testováno několik klasifikátorů včetně lineární diskriminační analýzy (LDA, z angl. Linear Discriminant Classifier), kvadratické diskriminační analýzy (QDA, z angl. Quadratic Discriminant Classifier), metody podpůrných vektorů (SVM, z angl. Support Vector Machines) a klasifikátoru k-nejbližšího souseda (kNN, z angl. k-Nearest Neighbor), přičemž nejlepší celkový výkon měřený v oblasti pod ROC (z angl. Receiver Operating Characteristic) křivkou vykazoval klasifikátor kNN.

Mirsharif G. a kol. [15] se ve své práci z roku 2011 věnovali vlastnostem cév v různých barevných prostorech, konkrétně v RGB a HSL prostoru (pozn. HSL prostor je definován odstínem, sytostí a světlostí barev) za účelem zisku nejlepších příznaků pro klasifikaci. Ze segmentovaného obrazu byla vytvořena kostra cév o tloušťce jednoho pixelu. Z této kostry byly odstraněny bifurkace, tedy místa protnutí tepny a žíly, kdy jeden pixel sousedí se čtyřmi pixely. Dále byly z kostry cév odstraněny i úseky, kde došlo k rozvětvení cévy, tzn. jeden pixel sousedí s třemi pixely.

Příznaky byly extrahovány z celých částí segmentů cév, jelikož po sobě jdoucí pixely v segmentovaných cévách mají podobné vlastnosti a patří ke stejnému typu

cévy. Vlastnosti, které se využily pro odlišení tepen od žil, byly založeny na barvě a šířce cév. Pro trénování bylo využito více druhů klasifikátorů, nejlepších výsledků však bylo dosaženo použitím LDA. Přesnost klasifikace hlavních cév a jejich větví dosahovala hodnoty 86 %.

Dashtbozorg B. a kol. [16] představili v roce 2014 ve své práci automatickou klasifikaci cév na základě analýzy grafu, který je extrahován z kostry vaskulární sítě sítnice. Metoda klasifikovala celý vaskulární strom určením každého typu průsečíku (uzel grafu) a označením každého segmentu cévy mezi dvěma průsečíky (vazba grafu). Typy průsečíků jsou následující: bod bifurkace (bod, ve kterém se céva rozvětňuje do užších částí), bod křížení (místo křížení tepny a žíly), bod setkání (místo, kde se oba typy cév setkávají, ale nedojde k jejich křížení) a bod spojení (místo spojení různých částí jedné cévy). O tom, o jaký průsečík se jedná, bylo rozhodnuto na základě geometrické analýzy grafu vaskulární sítě a následně byly extrahovány příznaky na základě měření intenzity segmentů cév pro konečné přiřazení třídy tepna či žíla.

Za účelem klasifikace cév byly testovány nejčastěji používané klasifikátory, tedy LDA, QDA a kNN, přičemž nejlepších výsledků dosahoval klasifikátor LDA.

Hamadnejad G. a Pourghassem H. [17] popisují ve své práci z roku 2015 extrakci několika barevných a směrových strukturálních příznaků. Pro extrakci strukturálních příznaků bylo využito diskrétní vlnkové transformace, projekčního modelování a mapování profilu cév. Následně využili analýzu hlavních komponent (PCA, z angl. Principal Components Analysis) pro optimalizaci všech příznaků a ty byly využity pro klasifikaci cév pomocí umělé neuronové sítě, konkrétně s využitím vícevrstvé perceptronové vrstvy (MLP, z angl. Multi-Layer Perceptron). MLP byla složena z jedné skryté vrstvy a počet neuronů v této vrstvě byl optimalizován pomocí fitness funkce na základě minimální střední kvadratické chyby.

Díky optimalizaci příznaků bylo v práci dosaženo vysoké senzitivity a specificity, přičemž míra přesnosti klasifikace byla 92,9 %.

Ayub L. a kol. [18] ve své práci z roku 2016 nejprve definovali oblast zájmu lokalizací optického disku v červeném kanálu RGB prostoru. Krevní cévy ležící v této oblasti zájmu byly s využitím zeleného kanálu RGB prostoru segmentovány pomocí bottom hat filtrace a ze segmentovaných cév byly následně extrahovány jejich příznaky. Extrakce příznaků proběhla s využitím jednotlivých kanálů RGB a HSV prostoru (pozn. HSV prostor je definován odstínem, sytostí a jasovou hodnotou barev) a s využitím texturních vlastností cév, kterými jsou kontrast, energie, entropie a homogenita. Jako klasifikátor byla zvolena umělá neuronová síť.

Přesnost navržené metody popsané v článku dosahovala 84,5 %.

Meyer M. I. a kol. [19] roku 2018 ve své práci popisují metodu s využitím konvoluční neuronové sítě (CNN, z angl. Convolutional Neural Network), která je upravena pro klasifikaci retinálních cév. Díky použití CNN při klasifikaci již není potřeba vytvářet kostru vaskulární sítě, ale dochází k přímé klasifikaci každého pixelu v cévě.

Pro klasifikační účel byla vytvořena kritériální funkce zaměřující se na pixely, které patřily pouze do vaskulární sítě. Jednotlivým třídám (pozadí, tepna a žíla) byly přiřazeny váhy, a aby bylo možné klasifikovat pouze cévy, třídě pozadí byla při trénování sítě přiřazena váha s hodnotou 0. Jako architektura CNN byla vybrána U-Net a k optimalizaci byl používán ADAM algoritmus.

Samotná klasifikace cév byla realizována na kanálech RGB snímků a na kombinacích jednotlivých kanálů. Nejhorší výsledek klasifikace byl pozorován u kombinace GB kanálů (přesnost 82 %), nejlepších výsledků dosahovala kombinace RB kanálů a RGB (přesnost 84 %). Při klasifikaci pouze velkých cév byla přesnost rovna 96 %.

Huang F. a kol. [20] extrahovali ve své práci z roku 2018 enormní množství příznaků pro centrální pixely cév a pro výběr příznaků využili techniku založenou na genetickém vyhledávání za účelem zisku výsledné podmnožiny příznaků pro konečnou klasifikaci cév do tepen a žil.

Po segmentaci retinálních cév a získání binární masky bylo pro každý centrální pixel cév extrahováno celkem 455 příznaků. Pro nalezení těch příznaků, které poskytují nejlepší výkon klasifikátoru, byla využita technika genetického vyhledávání. Tento evoluční algoritmus je založen na procesu přirozeného výběru v biologii, tedy šance na přežití jedince v určitém prostředí je dána kombinací jeho fenotypových znaků, které jsou dědičné (jsou kódovány genetickou sekvencí v chromozomech) a předávají se po několik generací.

Při využití tohoto konceptu pro selekci příznaků byly fenotypové znaky extrahované příznaky a genetická sekvence byla binárním vektorem, kde hodnota 1 nebo 0 určovala, zda je nebo není příznak využit. Pro každou generaci byli vybíráni rodiče a bylo získáno jejich potomstvo pářením a mutací. Následně byli vybráni přeživší. Simulací evoluce byla zajištěna konvergence ke globálnímu optimu v příznakovém prostoru a byla získána podmnožina příznaků splňující požadovanou přesnost.

Pro klasifikaci cév bylo využito klasifikátoru LDA, přičemž přesnost klasifikace dosahovala hodnoty 90,2 %.

Yin Xiao-Xia a kol. [21] ve své práci z roku 2019 zkoumali výkon různých kombinací klasifikátorů pro klasifikaci cév sítnice. Nejprve byl detekován optický disk za účelem definice zájmové kruhové oblasti v určité vzdálenosti okolo disku. Z vymezené oblasti zájmu byly segmentovány cévy a z nich extrahována sada příznaků. Příznaky byly pomocí Pearsonova korelačního koeficientu a metody Relief-F seřazeny a následně byly vybrány ty příznaky, jejichž použití zajistilo maximální přesnost

klasifikace. Samotná klasifikace cév probíhala kombinací jednotlivých klasifikátorů zahrnující kNN, SVM a naivního Bayesova klasifikátoru.

Remeseiro B. a kol. [22] představili v roce 2020 plně automatickou metodu pro klasifikaci retinálních cév, která poskytuje spolehlivé výsledky bez jakéhokoli trénovacího kroku.

Snímek sítnice byl nejprve segmentován pro získání optického disku a krevních cév, a následně byly extrahovány příznaky cév na základě lokálního kontrastu. Hodnoty lokálního kontrastu byly počítány jako rozdíl intenzit pixelů cév a intenzit pozadí. Při výpočtu lokálního kontrastu byl použit pouze červený kanál RGB prostoru, jelikož vykazuje nejlepší rozlišovací schopnosti mezi tepnami a žilami.

Paralelně s výpočtem kontrastu byl počítán graf vaskulární sítě. Pro získání grafu bylo potřeba získat pixely centrálních linií cév ze segmentovaného obrazu, aby byla vytvořena vaskulární síť složená z uzlů a vazeb. Následovala modifikace grafu a klasifikace uzlů do jednotlivých kategorií (bod bifurkace, křížení, setkání a spojení). Pro klasifikaci uzlů do kategorií byl využíván stupeň uzlu, tj. počet sousedních uzlů, a další charakteristiky jako úhel mezi spojenými vazbami.

Po výpočtu lokálního kontrastu a grafu bylo využito víceúrovňové prahování založené na Otsu metodě, díky které byly nalezeny prahové hodnoty minimalizující rozdíly v kontrastu jedné třídy pro výpočet částečné klasifikace s třídami: tepna, žíla a nejistota. Pro získání konečné klasifikace cév byl navržen algoritmus pro šíření grafu, který využíval informací získaných z výsledného grafu vaskulární sítě a z víceúrovňového prahování, tj. typy uzlů grafu a částečná klasifikace segmentů.

Raj P. Kevin a kol. [23] v roce 2020 navrhli metodu pro klasifikaci jednotlivých cév sítnice pomocí konvolučních neuronových sítí, konkrétně využívali síť ResNet-50 a bloky "Squeeze-Excite". Jimi navrhovaná síť pak nese název A-V Net (Artery-Vein Net). Metoda nevyžadovala předzpracování obrazu či segmentaci retinálních cév, vstupem do sítě byl samotný barevný obraz očního pozadí. Přesnost klasifikace cév navržené metody dosahovala 93,4 %.

## 4 Klasifikace cévního řečiště s využitím metod strojového učení

### 4.1 Strojové učení

Strojové učení se řadí do podoblasti umělé inteligence a zabývá se algoritmy, které umožňují počítači proces učení, tj. zlepšování se na základě získaných zkušeností [24].

Algoritmy strojového učení se dělí na učení s učitelem, učení bez učitele a zpětnovazebné učení. Při učení s učitelem je v trénovací množině dat zahrnuta také požadovaná výstupní hodnota a v případě učení bez učitele je soubor dat rozdělen na základě podobnostního kritéria do shluků, které mohou představovat predikovanou třídu či hledaný objekt [24, 25].

Mezi nejběžnější úlohy strojového učení se řadí klasifikace, regrese či shlukování.

### 4.2 Klasifikační algoritmy

Mezi algoritmy strojového učení zabývající se klasifikací se řadí logistická regrese, naivní bayesovský klasifikátor, algoritmus k-nejbližších sousedů, metoda podpůrných vektorů, rozhodovací stromy, neuronové sítě a další [24].

Pro rozpoznání jednotlivých objektů, kterými jsou v případě této práce cévy, a jejich zařazení do určitých tříd, jejichž počet je dopředu znám, je potřeba klasifikátoru, který objekty klasifikuje na základě extrahovaných příznaků.

#### 4.2.1 SVM klasifikátor


Metoda podpůrných vektorů je metodou strojového učení s učitelem. Záměrem SVM je vytvořit takový model, který bude predikovat třídy vstupních dat.

SVM má za cíl nalézt oddělující nadrovinu, která bude správně klasifikovat množinu dat. Při předpokladu vstupní množiny dat, která je lineárně separovatelná, je rovnice oddělující nadroviny definována jako

$$g(x) = w \cdot x + b = 0, \quad (4.1)$$

kde  $w$  je vektor vah,  $x$  je příznakový vektor dat a  $b$  je práh [26, 27].

Zjednodušený princip SVM je graficky znázorněn na Obr. 4.1. Vzdálenost mezi nadrovinou a nejbližšími vektory vstupních dat, tzv. podpůrnými vektory, je dána šířkou okraje. Pro správnou klasifikaci dat je potřeba šířku okrajů maximalizovat, aby byla data patřící do dvou různých tříd co nejdále od sebe [26, 27].



Obr. 4.1: Grafické znázornění principu lineárního SVM klasifikátoru na příkladu klasifikace dat do dvou lineárně separabilních tříd

Znázorněný princip platí pro množinu dat, kterou lze lineárně separovat, což ve většině případů není možné a je potřeba využít nelineární klasifikátor, který je založen na tzv. kernel přístupu využívající kernel trik [26, 27].

Hlavní myšlenkou kernel přístupu je transformace vstupních dat do nového příznakového prostoru s vyšším počtem dimenzí, kde již lze využít lineárního klasifikátoru pro oddělení dat do jednotlivých tříd. Kernel trik však využívá výpočtu skalárního součinu vektorů ve vyšších dimenzích bez nutnosti transformace dat do vyšší dimenze, čímž lze obejít omezení lineárních metod klasifikace [26, 27].

V praxi se využívají jednotlivé kernel funkce, kterými jsou např. polynomiální, radiální bázová funkce a další [26, 27].

### 4.3 Umělé neuronové sítě


Umělé neuronové sítě jsou inspirovány těmi biologickými, kdy by měly uměle vytvořené neuronové sítě být schopny se chovat podobně, jako biologické neuronové sítě [28].

Základními vlastnostmi umělých neuronových sítí je paralelní zpracování a předávání informací při provádění výpočtů, ukládání znalostí prostřednictvím síly vazeb mezi jednotlivými neurony a samotné učení neuronové sítě. Základními prvky neuronových sítí jsou pak umělé neurony, tzv. perceptrony, které jsou vzájemně propojeny v jednotlivých vrstvách sítě [28].

### 4.4 Hluboké učení

Hluboké učení spadá do podoblasti strojového učení a umožňuje výpočetním modelům složených z velkého množství skrytých vrstev učit se a vytvářet mnoho úrovní abstrakce reprezentace dat. Metody hlubokého učení byly průlomové především v oblastech zpracování obrazů, videa či rozpoznávání řeči a zvuků [29].

Srovnání jednoduché umělé neuronové sítě a umělé neuronové sítě hlubokého učení je znázorněno na Obr. 4.2.



Obr. 4.2: Grafické srovnání jednoduché umělé neuronové sítě a umělé neuronové sítě hlubokého učení



### 4.4.1 Konvoluční neuronové sítě

Konvoluční neuronové sítě (CNN) byly vytvořeny pro zpracování dat, která mají topologii podobnou mřížce, tzn. například pro zpracování obrazových dat, která lze považovat za 2D mřížku pixelů. Název těchto sítí napovídá, že je zde využíváno matematické operace konvoluce. Operaci konvoluce lze pro 2D obraz vyjádřit jako

$$g(x, y) = f(x, y) * h(x, y) = \sum_m \sum_n f(x - m, y - n) \cdot h(m, n), \quad (4.2)$$

kde  $g(x, y)$  je výstupní obraz (příznaková mapa),  $f(x, y)$  je vstupní obraz a  $h(x, y)$  je tzv. konvoluční jádro [25].

Základními vlastnostmi konvolučních neuronových sítí jsou lokální propojení neuronů, sdílení vah a využívání velkého počtu skrytých vrstev [25, 29].

Architektura typické CNN zahrnuje čtyři typy vrstev: konvoluční, aktivační, pooling (vrstva podvzorkování) a plně propojenou vrstvu [29, 30].

#### Konvoluční vrstva

Konvoluční vrstva slouží pro extrakci příznaků vstupních dat. Vstupní obraz je konvolován s konvolučním jádrem (filtrem) o určité velikosti, přičemž na výstupu je získán takový počet příznakových/aktivačních map, jaký byl použit počet konvolučních jader [29, 30].

#### Aktivační vrstva

Aktivační vrstva transformuje vstupní aktivační mapu pomocí aktivační funkce. Nejvyužívanějšími aktivačními funkcemi jsou ReLU či softmax jako výstupní funkce poslední vrstvy sítě pro klasifikační úlohy [29, 30].

#### Pooling vrstva

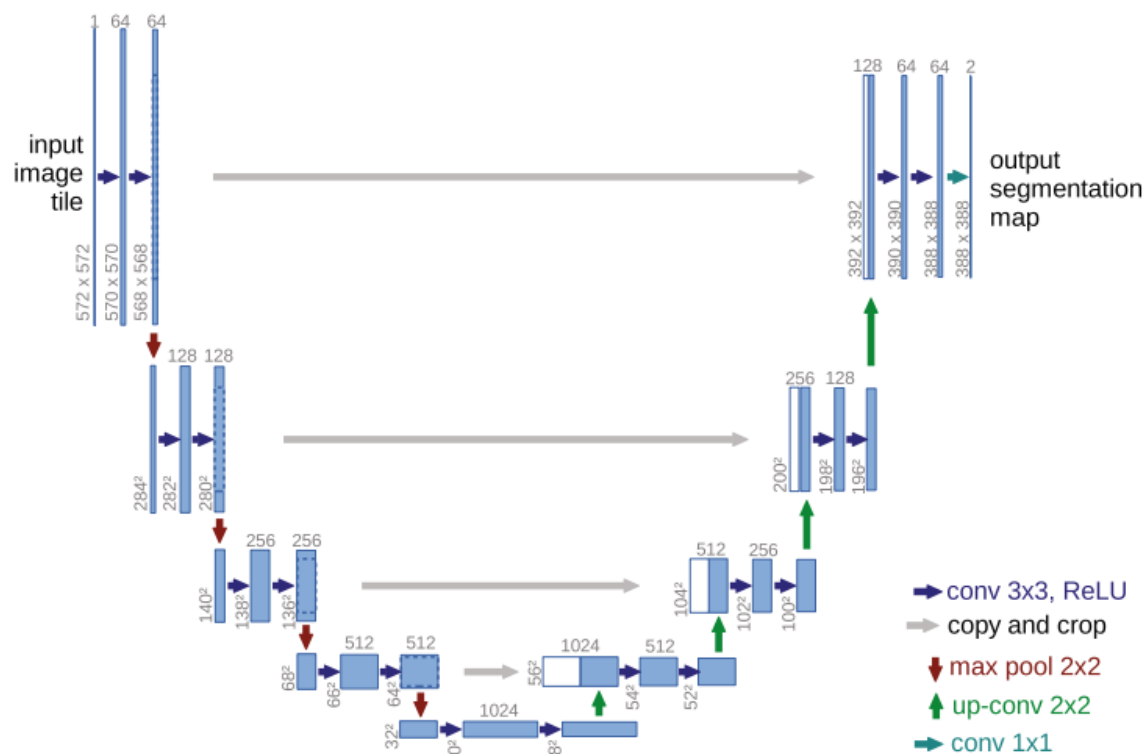
Pooling vrstva redukuje vstupní mapu (avšak v hloubce zůstává vstup nezměněn) pomocí nalezení maxima či průměrné hodnoty ze zadaného okna vstupní mapy. Pooling vrstva tak zajišťuje robustnost sítě vůči šumu a zkreslení [29, 30].

#### Plně propojená vrstva

Plně propojená vrstva je nejčastěji v CNN využívána jako vrstva konečná, přičemž výstup vrstvy je dán lineární kombinací jednotlivých neuronů a vstupních dat [29, 30].

## 4.4.2 U-Net

U-Net je architektura založena na konvolučních neuronových sítích a byla vyvinuta pro segmentaci biomedicínských obrazů. Architektura má tvar písmene U (viz Obr. 4.3) a je složena ze dvou částí, z části kontraktilní a expanzivní [31].



Obr. 4.3: U-Net architektura [31]

Kontraktilní část zahrnuje opakovanou aplikaci dvou konvolučních vrstev s velikostí konvolučního jádra 3x3. Konvoluční vrstva je následována ReLU aktivační vrstvou a pooling vrstvou s velikostí okna 2x2 a krokem 2, přičemž je v každém kroku podvzorkování zdvojnásoben počet příznakových map [31].

Expanzivní část architektury zahrnuje nadvzorkovací vrstvy s velikostí okna 2x2 a opakující se dvě konvoluční vrstvy s velikostí konvolučního jádra 3x3. Každá konvoluční vrstva je opět následována ReLU aktivační vrstvou. Na závěr je jako finální vrstva U-Net architektury používána konvoluční vrstva o velikosti konvolučního jádra 1x1. Celkový počet konvolučních vrstev obsažených v síti je 23 [31].

## 5 Návrh a realizace metod pro klasifikaci cévního řečiště

Na základě prostudovaných prací zabývajících se klasifikací cév a vypracování jejich řešerše, viz kap. 3, byly navrženy dvě klasifikační metody, díky kterým lze ze snímků sítnice klasifikovat retinální cévy na tepny a žíly. Metody klasifikují cévy s využitím SVM klasifikátoru a konvoluční neuronové sítě U-Net.

Oba klasifikační algoritmy byly zpracovány v programovacím prostředí Matlab R2020b. Neuronová síť U-Net byla navíc trénována v programovacím prostředí Matlab R2019b pomocí GPU NVIDIA GeForce GTX 1060 6GB využívající CUDA architekturu.

### 5.1 Použitá data

#### 5.1.1 RITE dataset


RITE (Retinal Images Vessel Tree Extraction) dataset [32] je založen na veřejně dostupné DRIVE (Digital Retinal Images for Vessel Extraction) databázi.

Fotografie pro databázi DRIVE byly získány z programu screeningu diabetické retinopatie v Nizozemsku, do něhož bylo zahrnuto 400 vybraných subjektů ve věku 25 – 90 let. Snímky byly snímány non-mydriatickou kamerou Canon CR5 3CCD se zorným polem  $45^\circ$  a s rozlišením  $565 \times 584$  pixelů. Z nasnímaných fotografií bylo náhodně vybráno 40 snímků, přičemž 33 z nich nevykazuje žádné diabetické retinopatie a 7 snímků vykazuje známky mírné a časně diabetické retinopatie [33].

RITE dataset obsahuje sadu 40 obrazů, přičemž každá sada sestává z fotografie očního pozadí, masky manuálně segmentovaných cév a obrazu s klasifikovanými cévami na tepny a žíly. Sady obrazů jsou rovnoměrně rozděleny na trénovací a testovací podmnožinu.

Referenční obraz s klasifikovanými retinálními cévami sestává z barevně odlišených cév. Tepny jsou konkrétně označeny červenou barvou, žíly jsou označeny barvou modrou a místa, na kterých dochází k překryvu tepen a žil, jsou označeny zeleně. Cévy, jejichž přiřazení k jedné ze tříd bylo nejisté, jsou označeny bílou barvou.

Zatímco jsou obrazy obsahující klasifikované cévy a masky segmentovaných cév ve formátu PNG, fotografie fundu jsou ve formátu TIF. Příklad jednotlivých dat z RITE datasetu je zobrazen na Obr. 5.1.




Obr. 5.1: Příklad dat z RITE datasetu. Snímek očního pozadí, maska segmentovaných cév a obraz klasifikovaných cév (zleva).

### 5.1.2 IOSTAR dataset


Snímky sítnice obsažené v IOSTAR datasetu [34] jsou nasnímány EasyScan kamerou (i-Optics Inc., Nizozemsko) se zorným polem  $45^\circ$  a s rozlišením  $1024 \times 1024$  pixelů. Kamera EasyScan je založena na technologii SLO (skenovací laserová oftalmoskopie, z angl. Scanning Laser Ophthalmoscopy) využívající konfokální laserovou skenovací mikroskopii pro diagnostické zobrazení sítnice lidského oka [35, 36].

IOSTAR dataset obsahuje celkem 30 snímků sítnice, přičemž součástí této datové sady jsou také masky zorného pole a masky jednotlivých optických disků. Dataset dále obsahuje masky segmentovaných retinálních cév a obrazy s klasifikovanými cévami na tepny a žíly. Tepny jsou označeny červenou a žíly modrou barvou.

Zatímco jsou obrazy obsahující klasifikované cévy a jednotlivé segmentační masky ve formátu TIF, fotografie fundusu jsou ve formátu JPEG. Příklad jednotlivých dat z IOSTAR datasetu je zobrazen na Obr. 5.2 a Obr. 5.3.



Obr. 5.2: Příklad dat z IOSTAR datasetu. Snímek očního pozadí, maska segmentovaných cév a obraz klasifikovaných cév (zleva).



Obr. 5.3: Příklad dat z IOSTAR datasetu. Maska zorného pole a maska optického disku (zleva).


### 5.1.3 AFIO dataset

Dataset [37] obsahuje 100 digitálních snímků fundusu, přičemž jsou tyto snímky získány experty z Armed Forces Institute of Ophthalmology (AFIO), Rawalpindi v Pákistánu. Soubor dat byl vytvořen oftalmology za účelem pomoci lékařům či výzkumným pracovníkům při screeningu hypertenzní retinopatie, diabetické retinopatie a papiledému [38].

Snímky očního pozadí byly nasnímány non-mydriatickou kamerou TOPCON TRC-NW8 se zorným polem  $30^\circ$  a s rozlišením  $1504 \times 1000$  pixelů [38].

Datová sada obsahuje jak snímky sítnice, tak masky segmentovaných retinálních cév a obrazy s klasifikovanými cévami na tepny a žíly. Tepny jsou označeny červenou barvou a žíly barvou modrou.

Snímky očního pozadí jsou ve formátu JPEG a segmentační masky cév jsou společně s obrazy sítnice obsahující klasifikované cévy ve formátu TIF. Příklad jednotlivých dat z AFIO datasetu je zobrazen na Obr. 5.4.



Obr. 5.4: Příklad dat z AFIO datasetu. Snímek očního pozadí, maska segmentovaných cév a obraz očního pozadí doplněný o klasifikované cévy (zleva).

## 5.2 Příprava dat pro klasifikaci cévního řečiště

Snímky z AFIO datasetu bylo potřeba, za účelem další práce s nimi, upravit. Provedené úpravy zahrnoval ořez a zmenšení snímků sítnice z velikosti  $1504 \times 1000$  na velikost  $1069 \times 909$ . Nová velikost snímků byla zvolena s ohledem na to, aby snímky sítnice neobsahovaly nadbytečné černé pozadí, které není předmětem zájmu, a aby velikost fundus snímků korespondovala s velikostí segmentačních masek cév. Dále byly snímky sítnice s klasifikovanými cévami vynásobeny s příslušnými segmentačními maskami, čímž vznikl obraz, ve kterém byly klasifikovány retinální cévy na černém pozadí.

Po detailnějším prohlédnutí snímků z AFIO datasetu byla zjištěna duplikace jednoho snímku sítnice a jedna chybná klasifikace cév, která neodpovídala poloze cév ve snímku sítnice. Tyto snímky byly z datasetu odstraněny, čímž se snížil počet snímků v datasetu ze 100 na 98.

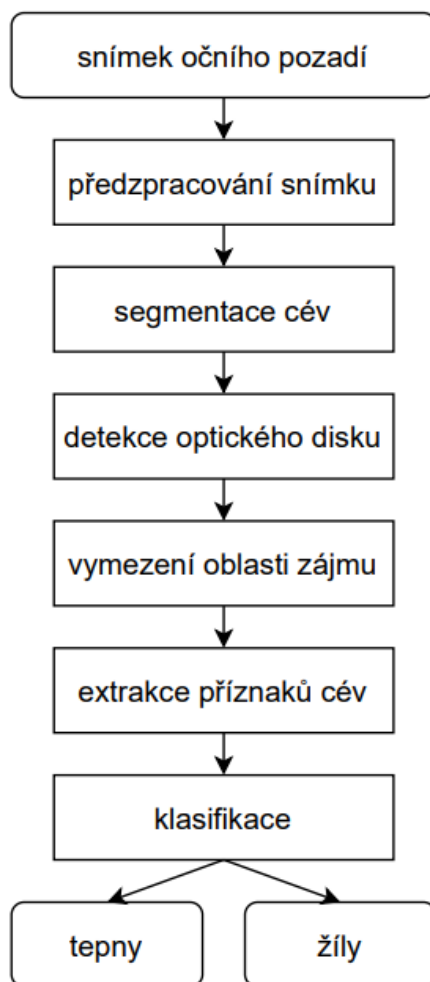
Data ze zbývajících databází dodatečné úpravy nevyžadovala.

### Trénovací a testovací množina dat

Metody, které byly navrženy za účelem klasifikace retinálních cév, využívají algoritmů strojového učení s učitelem. Snímky sítnice a jim odpovídající data (segmentační masky, ground truth obrazy s klasifikovanými cévami atd.) tak byly za účelem natrénování a otestování klasifikačních algoritmů rozděleny na trénovací a testovací množinu dat. Z každého datasetu bylo 80 % dat trénovacích a 20 % dat testovacích.

## 5.3 Klasifikace cévního řečiště s využitím SVM klasifikátoru

První metoda je založena na klasifikaci extrahovaných příznaků retinálních cév s využitím SVM klasifikátoru. Vývojový diagram metody je zobrazen na Obr. 5.5.




Obr. 5.5: Vývojový diagram klasifikace cév sítnice

Po načtení snímků očního pozadí je potřeba data vhodně předzpracovat. V tomto kroku dochází k lepší vizualizaci cév, či k odstranění šumu. Dalším krokem metody je segmentace cév a detekce optického disku. Díky segmentovaným cévám a znalosti polohy optického disku si lze generovat binární masku pro vymezení oblasti zájmu ve snímku, ve které dojde k samotné klasifikaci cév. Následuje extrakce příznaků z jednotlivých cév a klasifikace, jejíž výstupem budou pixely cév rozdělené na tepny a žíly.


### 5.3.1 Předzpracování snímků sítnice

Vstupní RGB snímek očního pozadí byl nejprve rozložen na barevné kanály, tedy na červený, zelený a modrý kanál, viz Obr. 5.6. Z jednotlivých kanálů RGB prostoru lze vidět, že optický disk je nejvíce znatelný v červeném kanálu, zatímco cévy sítnice jsou nejvíce odlišitelné v kanálu zeleném. Snímek v RGB prostoru byl dále převeden do HSV prostoru, ve kterém byl taktéž rozdělen na jednotlivé složky.



Obr. 5.6: Červený, zelený a modrý kanál snímku v RGB prostoru (zleva)

Dalším krokem zpracování snímku očního pozadí byla adaptivní ekvalizace histogramu, čímž došlo k úpravě kontrastu a zvýraznění detailů ve snímku. Originální snímek v červeném kanálu RGB prostoru a jeho následná úprava kontrastu je zobrazena na Obr. 5.7.




Obr. 5.7: Originální snímek a jeho úprava adaptivní ekvalizací histogramu (zleva)



### 5.3.2 Detekce středu optického disku a vymezení oblasti zájmu klasifikace


Za účelem vymezení oblasti zájmu, ve které bude probíhat klasifikace cév, byla potřeba detekovat optický disk (OD). Na snímek sítnice v červeném kanálu (nebo v zeleném kanálu v závislosti na konkrétním snímku) z RGB prostoru byla nejprve aplikována morfologická operace, konkrétně operace uzavření, která měla za následek eliminaci cév ve snímku. Následně byl optický disk segmentován pomocí metody geodesických aktivních kontur. Příklad eliminace cév ze snímku a umístění počátečních bodů kontury okolo optického disku je zobrazen na Obr. 5.8.




Obr. 5.8: Eliminace cév ve snímku a zadání počátečních bodů kontury (zleva)

Ze segmentovaného OD byly zjištěny souřadnice jeho středu a byla generována kruhová binární maska okolo optického disku s průměrem dvakrát větším, než je OD. Při generování binární masky byla předpokládána konstantní hodnota průměru OD, kdy byla s touto hodnotou pokryta drtivá většina optických disků v trénovací i testovací sadě obrazů. Na Obr. 5.9 je zobrazen barevný snímek sítnice s vyznačenou oblastí zájmu okolo optického disku (první zleva). Binární maska oblasti zájmu byla následně vynásobena s maskou segmentovaných cév, viz třetí obrázek zleva na Obr. 5.9.

Za účelem další analýzy cév byl z masky segmentovaných cév vytvořen skelet cévního řečiště, ze kterého byly odstraněny bifurkace a body křížení (viz Obr. 5.10 vlevo). Výsledný skelet byl následně taktéž vynásoben s binární maskou oblasti zájmu, viz obrázek vpravo na Obr. 5.10.



Obr. 5.9: Binární maska oblasti zájmu okolo optického disku



Obr. 5.10: Skeleton cévního řečiště a výsledek jeho vynásobení s binární maskou oblasti zájmu (zleva)

### 5.3.3 Extrakce příznaků

Příznaky jsou specifické vlastnosti pro určitý objekt, pomocí kterých jej lze klasifikovat. V případě této práce jsou objekty cévy a z jednotlivých pixelů cév se tedy extrahují příznakové vektory popisující jejich vlastnosti, které jsou pro tepny a žíly odlišné, viz podkap. 1.2.3.

Příznaky extrahované pro klasifikaci cév lze rozdělit na statistické a texturní. Statistické příznaky jsou extrahovány z jednotlivých kanálů barevných prostorů (RGB, HSV), kdy je získána hodnota intenzity, resp. její průměr, směrodatná odchylka či rozptyl. Texturní příznaky lze odvodit z koincidenční matice stupňů šedi [18].

#### Barevné prostory

Model RGB (R - červená složka, G - zelená složka, B - modrá složka) je založen na vnímání barev lidským okem a všechny barvy v tomto prostoru jsou vytvářeny sčítáním jednotlivých barevných složek. Prostor HSV (H (hue) - barevný tón, S (saturation) - sytost barvy, V (value) - hodnota jasu) je využíván především v počítačové grafice k míchání barev. [39].

#### Koincidenční matice stupňů šedi

Koincidenční matice stupňů šedi (GLCM, z angl. Gray Level Co-occurrence Matrix) se využívá při zkoumání textury a zohledňuje vzájemnou polohu pixelů. GLCM nese informaci o vzájemném vztahu jasu definované dvojice pixelů, přičemž dvojice je dána jako relativní souřadnice druhého pixelu vzhledem k prvnímu, anebo jako vzdálenost dvou pixelů a orientovaný úhel, který svírá spojnice těchto pixelů [39].

Rozměr koincidenční matice je  $n \times n$ , kde  $n$  je počet stupňů šedi v obraze. Hodnoty jasu určené dvojice pixelů představují indexy prvku v matici, jehož hodnota bude zvýšena o jedna. Poté, co jsou všechny dvojice pixelů vyčerpány, každý prvek matice je vydělen součtem všech prvků, čímž je získána pravděpodobnost výskytu dvojice pixelů [39].

GLCM se využívá při segmentaci či klasifikaci obrazů. V Matlabu lze předdefinovanou funkcí odvodit jednotlivé charakteristiky z koincidenční matice, které poskytují informaci o textuře obrazových dat, konkrétně se jedná o odvození hodnot kontrastu, korelace, energie a homogenity.

#### Distanční matice

Rozdíl mezi šířkou tepny a žíly je nejvíce znatelný v oblasti okolo optického disku. Pro odhad šířky cév lze vypočítat distanční matici, kdy je z masky segmentovaných cév počítána euklidovská vzdálenost každého centrálního pixelu cévy k nejbližšímu

pixelu pozadí. Za účelem eliminace nepřesností hodnot šířek cév, způsobené např. jejich vzájemným překryvem, je distanční matice filtrována maskou o zvolené velikosti [20].

Pomocí binární masky oblasti zájmu se segmentovanými cévami byly ze snímků očního pozadí sítnice extrahovány příznaky, mezi kterými byla průměrná hodnota, směrodatná odchylka a rozptyl intenzity z posuvného okna o velikosti  $3 \times 3$  pixelů v jednotlivých kanálech RGB a HSV prostorů. Dále byl na centrální pixely cévního řečiště v červeném, zeleném a modrém kanálu RGB prostoru aplikován 2D Gaussův filtr s hodnotou směrodatné odchylky 1, 2, 4, a 8. Následně byla ze samotných centrálních pixelů cév, tedy ze skeletonu cévního řečiště, extrahována hodnota intenzity z kanálů RGB a HSV prostoru a bylo procházeno okolí každého z centrálních pixelů. Z okolí centrálního pixelu byl vypočítán průměr, směrodatná odchylka a entropie a výsledná hodnota byla uložena na pozici odpovídající centrálnímu pixelu cévy. Dalším extrahovaným příznakem byla distanční matice.


Mezi posledními extrahovanými příznaky byly příznaky texturní, tedy kontrast, korelace, energie a homogenita vypočítané pomocí koincidenční matice stupňů šedi.

Celkem bylo extrahováno 80 příznaků.

### Výběr příznaků

K posouzení využitelnosti příznaků byly jejich hodnoty nejprve normalizovány a poté z nich byly vytvořeny boxploty, ze kterých je na první pohled zřejmé, jak moc jsou hodnoty příznaků odlišné pro tepny a žíly. Boxplot, neboli krabicový graf, je jednou z grafických metod a zobrazuje hodnotu maxima a minima, 1. a 3. kvartil, medián a odlehlé hodnoty. Na základě vytvořených boxplotů pro každý příznak pro tepnu a žílu byly některé příznaky vyloučeny a byla sestavena sada příznaků, která sloužila pro klasifikaci cév.


Příklad boxplotu hodnot intenzity centrálních pixelů tepen a žil v zeleném kanálu (na Obr. 5.11 vlevo) a boxplotu hodnot směrodatných odchylek sytosti pixelů tepen a žil (na Obr. 5.11 vpravo) je znázorněn na Obr. 5.11. Tepna je reprezentována hodnotou 2 a žíla hodnotou 3. Z vykreslených boxplotů lze říci, že hodnoty směrodatných odchylek sytosti pixelů se pro tepnu a žílu neliší a takovýto příznak není vhodný pro klasifikaci cév a do sady příznaků pro klasifikaci nebyl vybrán. Hodnoty intenzity centrálních pixelů v zeleném kanálu jsou pro tepny a žíly rozdílné, a proto byl tento příznak přidán do sady příznaků pro klasifikaci.




Obr. 5.11: Boxploty dvou vybraných příznaků

Do příznakové sady bylo po posouzení jejich využitelnosti vybráno celkem 36 příznaků (z celkového množství 80 příznaků), konkrétně 16 příznaků extrahovaných z centrálních pixelů (distanční matice, intenzita pixelů v jednotlivých kanálech RGB prostoru a HSV prostoru s výjimkou intenzity pixelů saturace, průměrná hodnota získaná z okna 3x3 se středem v centrálním pixelu cévy v jednotlivých kanálech RGB i HSV prostoru a stejným způsobem získaná hodnota směrodatné odchylky barevného tónu a hodnota entropie zeleného kanálu, barevného tónu a jasu) a 20 příznaků extrahovaných ze všech pixelů cév (průměrná hodnota všech barevných kanálů, hodnota směrodatné odchylky všech barevných kanálů s výjimkou saturace a hodnota pixelů cév po aplikaci 2D Gaussova filtru s hodnotou směrodatné odchylky 2, 4 a 8 v červeném, zeleném a modrém kanálu RGB prostoru).


Pro naznačení kvality použitých příznaků jsou některé příznaky, které byly součástí příznakové sady určené pro trénování klasifikátoru SVM, zobrazeny ve formě boxplotů na obrázcích níže. Na Obr. 5.12 je zobrazen příznak distanční matice vypočítané pro centrální pixely cév (vlevo) a příznak průměrné hodnoty jasu pixelů cév (vpravo). Dále je na Obr. 5.13 zobrazen příznak průměrné intenzity centrálních pixelů v červeném kanálu RGB prostoru (vlevo) a příznak průměrné intenzity centrálních pixelů v zeleném kanálu RGB prostoru (vpravo). Na závěr je na Obr. 5.14 zobrazen příznak intenzity pixelů cév po aplikaci 2D Gaussova filtru s hodnotou směrodatné odchylky 2 v modrém kanálu RGB prostoru (vlevo) a příznak intenzity pixelů cév po aplikaci 2D Gaussova filtru s hodnotou směrodatné odchylky 4 v zeleném kanálu RGB prostoru (vpravo).



Obr. 5.12: Boxplot distanční matice centrálních pixelů cévy boxplot průměrné hodnoty jasu pixelů (zleva)



Obr. 5.13: Boxplot průměrné intenzity centrálních pixelů v červeném kanálu RGB prostoru a boxplot průměrné intenzity centrálních pixelů v zeleném kanálu RGB prostoru (zleva)



Obr. 5.14: Boxplot intenzity pixelů po aplikaci 2D Gaussova filtru s hodnotou směrodatné odchylky 2 v modrém kanálu RGB prostoru a boxplot intenzity pixelů po aplikaci 2D Gaussova filtru s hodnotou směrodatné odchylky 4 v zeleném kanálu RGB prostoru (zleva)

### 5.3.4 Klasifikace

Posledním krokem navržené metody je klasifikace cév na tepny a žíly pomocí klasifikátoru SVM. Pro natrénování SVM bylo použito 32 trénovacích snímků z RITE databáze a následně byl naučený model testován na 8 snímcích, taktéž z RITE databáze.

Jelikož se jedná o metodu učení s učitelem, pro trénování klasifikátoru byla sestavena sada příznaků pro každý pixel cévy a každému pixelu byla přiřazena jemu odpovídající třída, tedy zda se jedná o pixel tepny (hodnota 2), anebo o pixel žíly (hodnota 3). Ty pixely cév, které byly expertem označeny jako neklasifikované nebo překrývající se žíla a tepna, byly z trénovacích i testovacích dat odstraněny.

Pro vytvoření modelu SVM klasifikátoru byl nejprve sestaven základní blok SVM pro standardizaci vstupních hodnot a jako kernel funkce byla zvolena radiální bazová funkce. Samotný model SVM byl vytvořen ze vstupní matice příznaků, vektoru tříd a základního bloku SVM.

Natrénovaný model byl následně využit jako vstup pro predikci tříd pixelů cév.

Výsledek klasifikace cévního řečiště s využitím SVM klasifikátoru je vyhodnocen v podkap. 6.2.

## 5.4 Klasifikace cévního řečiště s využitím konvoluční neuronové sítě U-Net

Druhá zvolená metoda využívá pro klasifikaci cév sítnice konvoluční neuronovou síť s architekturou U-Net.

Před tím, než je samotná síť vytvořena, je potřeba vstupní snímky, jak z trénovací, tak z testovací množiny, správně načíst a zakódovat. Dále je potřeba věnovat pozornost volbě trénovacích parametrů sítě, na základě kterých se bude zvolená síť učit.

### 5.4.1 Předzpracování dat

Pro natrénování konvoluční neuronové sítě je potřeba dostatečného množství trénovacích dat. Z toho důvodu byla trénovací i testovací množina dat sestavena sloučením dat z RITE, IOSTAR i AFIO databáze. Tímto sloučením bylo dosaženo velikosti trénovací množiny dat o 135 snímcích a velikost testovací množiny byla 33 snímků.

Nezbytným krokem předzpracování dat vstupujících do neuronové sítě je úprava jejich velikosti. Všechna data z trénovací i testovací množiny byla zmenšena na jednotnou velikost  $560 \times 576$  pixelů.

Trénovací i testovací množina dat sestává z RGB snímků sítnice a z obrazů klasifikovaných cév. Právě obrazy klasifikovaných cév bylo potřeba zakódovat tak, aby byly reprezentovány jako matice obsahující numerické hodnoty v závislosti na počtu klasifikovaných tříd o velikosti  $560 \times 576$  pixelů. Z toho důvodu, že je potřeba každému pixelu obrazu přiřadit určitou třídu, nebyly klasifikovány pouze pixely cév, ale také pixely pozadí, tj. snímek sítnice byl klasifikován do tří tříd. Matice reprezentující obrazy klasifikovaných cév tak obsahovaly hodnoty 1, 2 a 3. Numerická hodnota 1 byla přiřazena pixelům pozadí, hodnota 2 byla přiřazena tepnám a numerická hodnota 3 byla přiřazena žilám.

### 5.4.2 Trénování sítě

Před samotným trénováním sítě bylo potřeba získat validační množinu dat, trénovací data augmentovat a zvolit parametry trénování.

#### Validační množina

Validační množina slouží k průběžnému ověřování učení sítě a zabraňuje jejímu přeučení. Za účelem vytvoření validační množiny byla trénovací data náhodně rozdělena v poměru 85 % a 15 %, kdy byla větší část množiny označena jako trénovací a zbylých 15 % dat sloužilo pro vytvoření validační množiny.



## Augmentace dat

Na trénovací množinu dat byla aplikována augmentace za účelem rozšíření trénovací množiny.

Augmentace je metodou, která zvyšuje robustnost neuronové sítě a zabraňuje jejímu přeučení v důsledku nedostatečného množství trénovacích dat. Nejpopulárnějším přístupem při augmentaci dat je aplikace afinních a elastických transformací na trénovací data. Augmentací vzniknou nové obrazy rotací, translací, zkosením, přiblížením či jiným zkreslením dat původních [31, 40].

## Ztrátová funkce

Aby se síť správně naučila, snaží se minimalizovat tzv. ztrátovou (neboli chybovou) funkci, která je dána rozdílem mezi skutečnou hodnotou a hodnotou vypočítanou neuronovou sítí [41].

Pro klasifikační úlohy je nejvíce využívanou funkcí cross-entropie, která počítá rozdíl mezi dvěma pravděpodobnostními rozděleními. Výběr typu cross-entropie je ovlivněn typem tříd, do kterých budou klasifikována vstupní data. V případě binární klasifikace je využívána binární cross-entropie a v případě klasifikace pixelů do více než dvou tříd bude použita kategoriální cross-entropie, která je vybrána jako ztrátová funkce pro učení sítě U-Net, kdy bude ve výstupní vrstvě počet neuronů roven počtu klasifikačních tříd [42, 43].

Kategoriální cross-entropii lze modifikovat na váhovanou kategoriální cross-entropii, což znamená, že bude každé třídě přiřazena hodnota váhy a pixely odpovídajících tříd pak budou klasifikovány s ohledem na přiřazené hodnoty vah [19].

## Optimalizační algoritmus

Optimalizační algoritmy slouží k minimalizaci ztrátové funkce a k úpravě parametrů sítě na základě nalezeného minima [41].

Základní a široce využívanou metodou pro nalezení minima ztrátové funkce je metoda gradientního sestupu, která však není vhodná pro trénování složitých neuronových sítí a jako optimalizační algoritmus pro natrénování sítě byl zvolen učící algoritmus ADAM (adaptivní výpočet momentu, z angl. Adaptive Moment Estimation). ADAM je stochastický optimalizační algoritmus, který využívá pro nalezení minima ztrátové funkce první a druhou hybnost gradientu s exponenciálním zapomínáním [41, 44].

## Trénovací proces sítě


Trénování sítě U-Net probíhalo na 30 epochách s 840 iteracemi a jako optimalizační algoritmus byl zvolen ADAM s krokem učení 0,0001. V průběhu trénování sítě se ukázalo, že velkou roli hraje právě nastavení vah ztrátové funkce. Z toho důvodu

bylo natrénováno hned několik neuronových sítí s experimentálně volenými váhami, jejichž hodnota byla vybrána vždy s ohledem na vypočítanou frekvenci jednotlivých pixelů za každou třídu. Po natrénování sítí byly vybrány dvě, které klasifikovaly snímky z testovací množiny nejlépe.


První neuronová síť byla natrénována s hodnotami vah 0,6 pro třídu pozadí, 17 pro tepny a 14 pro žíly. Druhá neuronová síť měla váhy nastaveny na hodnoty 0,7 pro třídu pozadí, 18 pro tepny a 14 pro žíly. Průběh trénování obou sítí je zobrazen na Obr. 5.15 a na Obr. 5.16.

Výsledná validační přesnost první sítě (Obr. 5.15) byla rovna 55,34 % a validační přesnost sítě druhé (Obr. 5.16) dosahovala hodnoty 62,40 %.

Výsledek klasifikace cévního řečiště s využitím konvoluční neuronové sítě je vyhodnocen v podkap. 6.3.



Obr. 5.15: Průběh trénování sítě s hodnotami vah 0,6 pro pozadí, 17 pro tepny a 14 pro žíly



Obr. 5.16: Průběh trénování sítě s hodnotami vah 0,7 pro pozadí, 18 pro tepny a 14 pro žíly

## 6 Výsledky klasifikace

Kapitola prezentuje výsledky klasifikačních metod, které byly v práci představeny a realizovány, viz kap. 5. Obě metody byly hodnoceny pomocí matic záměn.

### 6.1 Matice záměn

Matice záměn slouží k vyhodnocení výsledku klasifikace do dvou a více tříd a obsahuje informace o skutečné a predikované hodnotě třídy, viz Obr. 6.1.

		predikovaná třída	
		+	-
skutečná třída	+	TP	FN
	-	FP	TN

Obr. 6.1: Matice záměn

Na diagonále matice záměn je četnost správně klasifikovaných hodnot a buňky matice mimo diagonálu odpovídají četnosti chybně klasifikovaných hodnot. Konkrétními metrikami v matici záměn jsou [45]:

- TP (True Positive) - počet správně klasifikovaných do pozitivní třídy, tj. pozitivní hodnota je správně klasifikována do pozitivní třídy,
- FN (False Negative) - počet nesprávně klasifikovaných do negativní třídy, tj. pozitivní hodnota je chybně klasifikována do negativní třídy,
- FP (False Positive) - počet nesprávně klasifikovaných do pozitivní třídy, tj. negativní hodnota je chybně klasifikována do pozitivní třídy,
- TN (True Negative) - počet správně klasifikovaných do negativní třídy, tj. negativní hodnota je správně klasifikována do negativní třídy.

Z matice záměn lze dále vypočítat senzitivitu, specificitu, přesnost či chybovost klasifikace [45].

Senzitivita vyjadřuje míru pozitivních hodnot označených klasifikátorem jako pozitivní a je počítána jako

$$\text{senzitivita} = \frac{TP}{(TP + FN)} \quad (6.1)$$

Specificita vyjadřuje míru negativních hodnot označených klasifikátorem jako negativní a je počítána jako

$$specificita = \frac{TN}{(TN + FP)} \quad (6.2)$$

Přesnost udává počet všech správně klasifikovaných hodnot ku celkovému počtu hodnot, tj.

$$presnost = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (6.3)$$

Chybovost udává počet všech chybně klasifikovaných hodnot ku celkovému počtu hodnot, tj.

$$chybovost = 1 - presnost \quad (6.4)$$

## 6.2 Výsledek klasifikace cévního řečiště s využitím SVM klasifikátoru

Cévní řečiště na snímcích z RITE databáze bylo klasifikováno do dvou tříd, přičemž třídě reprezentující tepny byla přiřazena hodnota 2 a třídě reprezentující žíly hodnota 3.

Klasifikátor SVM byl natrénován na extrahovaných příznacích ze 32 snímků sítnice z trénovací množiny a následně byl již natrénovaný klasifikátor otestován na testovací množině dat ze stejné databáze, která zahrnuje 8 snímků sítnice nasnímaných fundus kamerou. Nejprve byly klasifikovány pouze cévy, které se nacházely v oblasti zájmu okolo optického disku, záhy byl klasifikátor otestován na cévách z celého snímku očního pozadí.

### 6.2.1 Klasifikace cév v oblasti zájmu okolo optického disku

Výsledek klasifikace cévního řečiště v oblasti zájmu okolo OD je reprezentován maticí záměn zobrazenou na Obr. 6.2. Ve výsledku klasifikace jsou zahrnuta všechna data z testovací množiny.


		predikovaná třída	
		tepna	žíla
skutečná třída	tepna	8615	4796
	žíla	4362	11535

Obr. 6.2: Výsledná matice záměn klasifikace cév ležících v oblasti zájmu okolo OD

Matice záměn zobrazuje četnosti klasifikovaných pixelů, přičemž 8615 pixelů bylo správně klasifikovaných jako tepna a 11535 pixelů bylo správně klasifikovaných jako žíla. Senzitivita vypočítaná z matice záměn klasifikace je rovna 64,24 %, tj. procento správně klasifikovaných pixelů tepen. Specificita klasifikace je rovna 72,56 %, tj. procento správně klasifikovaných pixelů žil. Celková přesnost klasifikace cév v oblasti zájmu okolo optického disku je rovna 68,75 % a chybovost klasifikace je rovna 31,25 %.

Pro vizuální znázornění výsledku klasifikace, a jeho porovnání s ground truth daty, byly vybrány dva snímky z testovací množiny a výsledek jejich klasifikovaných cév byl zpracován do podoby RGB obrazu vhodného pro porovnání s ground truth obrazy. Tepny jsou vykresleny červenou barvou a žíly barvou modrou.

Příklad výsledku klasifikace cév ve vymezeném okolí zájmu snímku 1 je zobrazen na Obr. 6.3 vlevo. Vpravo je ground truth obraz odpovídající výsledku klasifikace.




Obr. 6.3: Výsledek klasifikace cév snímku 1 a odpovídající ground truth obraz (zleva)

Matice záměn klasifikace cév z obrazu na Obr. 6.3 vlevo je zobrazena na Obr. 6.4. Počet správně klasifikovaných pixelů tepen je 1132, tedy 72,38 % pixelů tepen je klasifikováno jako tepna. Počet správně klasifikovaných pixelů žil je 1689, tj. 80,43 % pixelů žil je klasifikováno jako žíla. Celková přesnost klasifikace cév na odpovídajícím snímku sítnice dosahuje 76,99 % a chybovost klasifikace je rovna 23,01 %.

		<b>predikovaná třída</b>	
		tepna	žíla
<b>skutečná třída</b>	tepna	1132	432
	žíla	411	1689

Obr. 6.4: Výsledná matice záměn klasifikace cév snímku 1

Příklad výsledku klasifikace cév ve vymezeném okolí zájmu snímku 2 je zobrazen na Obr. 6.5 vlevo. Vpravo je opět zobrazen odpovídající ground truth obraz.



Obr. 6.5: Výsledek klasifikace cév snímku 2 a odpovídající ground truth obraz (zleva)

Matice záměn klasifikace cév z obrazu na Obr. 6.5 vlevo je zobrazena na Obr. 6.6. Počet správně klasifikovaných pixelů tepen je 1167, tedy 73,54 % pixelů tepen je správně klasifikováno jako tepna. Počet správně klasifikovaných pixelů žil je 1918, tj. 86,91 % pixelů žil je klasifikováno jako žíla. Celková přesnost klasifikace cév na odpovídajícím snímku sítnice dosahuje 81,31 % a chybovost klasifikace je rovna 18,69 %.

		predikovaná třída	
		tepna	žíla
skutečná třída	tepna	1167	420
	žíla	289	1918

Obr. 6.6: Výsledná matice záměn klasifikace cév snímku 2

Na vybraných obrazech s klasifikovanými cévami zobrazených na Obr. 6.3 a na Obr. 6.5 lze vidět, že klasifikace selhávala především na menších cévách a větší



cévy se z velké části podařilo klasifikovat správně. Z uvedených matic záměn klasifikací cév lze pozorovat, že pixely žil byly klasifikovány s vyšší úspěšností, než tomu bylo u pixelů tepen.

## 6.2.2 Klasifikace cév v celém snímku sítnice

Výsledek klasifikace cévního řečiště v celém snímku sítnice je reprezentován maticí záměn zobrazenou na Obr. 6.7. Matice záměn zobrazuje četnosti klasifikovaných pixelů z dat celé testovací množiny.


		predikovaná třída	
		tepna	žila
skutečná třída	tepna	59077	41312
	žila	41630	86532

Obr. 6.7: Výsledná matice záměn klasifikace cév v celém snímku sítnice

Počet správně klasifikovaných pixelů tepen je 59077 a počet správně klasifikovaných pixelů žil je 86532. Z matice záměn bylo vypočítáno, že 58,85 % pixelům tepen byla přiřazena třída 2, tj. třída tepna, a 67,52 % pixelů žil bylo klasifikováno jako třída 3, tj. třída žila. Celková přesnost klasifikace cév na tepny a žíly je rovna 63,71 % a celková chybovost klasifikace je 36,29 %.

Pro vizuální porovnání výsledku klasifikace s ground truth daty byly vybrány dva snímky z testovací množiny a jejich výsledek klasifikace cévního řečiště byl převeden na RGB obraz.

Příklad výsledku klasifikace cév v celém snímku 1 je zobrazen na Obr. 6.8 vlevo. Druhý obraz vpravo je odpovídajícím ground truth obrazem.




Obr. 6.8: Výsledek klasifikace cév snímku 1 a odpovídající ground truth obraz (zleva)

Matice záměn klasifikace cév z obrazu na Obr. 6.8 vlevo je zobrazena na Obr. 6.9. Počet správně klasifikovaných pixelů tepen je 6795, tj. 58,64 % pixelů tepen je klasifikováno jako tepna. Počet správně klasifikovaných pixelů žil je 10228, tj. 68,42 % pixelů žil je klasifikováno správně. Celková přesnost klasifikace cév na odpovídajícím snímku sítnice je 64,15 % a chybovost klasifikace je rovna 35,85 %.

		predikovaná třída	
		tepna	žila
skutečná třída	tepna	6795	4793
	žila	4721	10228

Obr. 6.9: Výsledná matice záměn klasifikace cév v celém snímku 1

Příklad výsledku klasifikace cév v celém snímku 2 je zobrazen na Obr. 6.10 vlevo. Vpravo je zobrazen odpovídající ground truth obraz.



Obr. 6.10: Výsledek klasifikace cév snímku 2 a odpovídající ground truth obraz (zleva)

Matice záměn klasifikace cév z obrazu na Obr. 6.10 vlevo je zobrazena na Obr. 6.11. Počet správně klasifikovaných pixelů tepen je 8334, tj. z matice záměn bylo vypočítáno, že 64,89 % pixelů tepen bylo klasifikováno jako tepna. Počet správně klasifikovaných pixelů žil je 11543, tj. 71,57 % pixelů žil bylo klasifikováno jako žíla. Celková přesnost klasifikace cév dosahuje hodnoty 68,61 % a celková chybovost klasifikace je 31,39 %.

		predikovaná třída	
		tepna	žíla
skutečná třída	tepna	8334	4509
	žíla	4585	11543

Obr. 6.11: Výsledná matice záměn klasifikace cév v celém snímku 2

Na vybraných obrazech z testovací množiny zobrazených na Obr. 6.8 a na Obr. 6.10 lze vidět, že klasifikace selhávala především na malých cévách a na cévách ležících na periférii sítnice. Dále lze z uvedených matic záměn klasifikací pozorovat, že docházelo k vyšší úspěšnosti klasifikace pixelů žil, než u pixelů tepen. Velké cévy se podařilo ve většině případů klasifikovat po celé své délce správně.

### 6.2.3 Shrnutí výsledku klasifikace s využitím SVM klasifikátoru

Natrénovaný SVM klasifikátor byl testován na celé testovací sadě snímků z RITE databáze a nejprve došlo ke klasifikaci cév ve vymezené oblasti zájmu okolo OD a následně byly cévy klasifikovány v celém snímku sítnice. Výsledky klasifikace jsou shrnuty v Tab. 6.1.

Tab. 6.1: Shrnutí výsledku klasifikace s využitím SVM klasifikátoru

	Klasifikace cév v oblasti zájmu	Klasifikace cév v celém snímku
Senzitivita [%]	64,24	58,85
Specifická [%]	72,56	67,52
Celková přesnost [%]	68,75	63,71
Celková chybovost [%]	31,25	36,29

## 6.3 Výsledek klasifikace cévního řečiště s využitím konvoluční neuronové sítě U-Net

Obě natrénované konvoluční neuronové sítě U-Net lišící se v počáteční iniciaci vah ztrátové funkce byly otestovány na 33 snímcích sítnice z testovací množiny dat a každý pixel obrazu byl zařazen do jedné ze tří tříd. Pixelu obrazu mohla být přiřazena hodnota 1, která reprezentuje třídu pozadí, dále mohl být pixel klasifikován do třídy 2 jako tepna, anebo byl označen třídou 3 jako žíla.

Na Obr. 6.12 a Obr. 6.13 jsou zobrazeny výsledné matice záměn klasifikace cév, které obsahují všechny četnosti pixelů z testovací množiny dohromady. Z důvodu velkého množství pixelů jsou matice záměn uvedeny také v jejich normalizovaných verzích.

		predikovaná třída		
		pozadí	tepna	žila
skutečná třída	pozadí	5389392	2351044	1809550
	tepna	183626	154806	114580
	žila	263985	219033	158464

		predikovaná třída		
		pozadí	tepna	žila
skutečná třída	pozadí	0,564	0,246	0,189
	tepna	0,405	0,342	0,253
	žila	0,412	0,341	0,247

Obr. 6.12: Výsledná matice záměn klasifikace cév a její normalizovaná verze (zleva). Zobrazeny výsledky neuronové sítě s váhami 0,6 pro pozadí, 17 pro tepny a 14 pro žíly.

		predikovaná třída		
		pozadí	tepna	žila
skutečná třída	pozadí	5899812	2025097	1625077
	tepna	227512	123858	101642
	žila	328717	173168	139597

		predikovaná třída		
		pozadí	tepna	žila
skutečná třída	pozadí	0,618	0,212	0,170
	tepna	0,502	0,273	0,224
	žila	0,512	0,269	0,218

Obr. 6.13: Výsledná matice záměn klasifikace cév a její normalizovaná verze (zleva). Zobrazeny výsledky neuronové sítě s váhami 0,7 pro pozadí, 18 pro tepny a 14 pro žíly.

Z normalizované matice záměn klasifikace cév neuronovou sítí s váhami 0,6 pro pozadí, 17 pro tepny a 14 pro žíly, zobrazené na Obr. 6.12 vpravo je patrné, že pixely pozadí byly úspěšně klasifikovány na 56,4 %, pixely tepen na 34,2 % a pixely žil na 24,7 %. Z matice záměn obsahující četnosti klasifikovaných pixelů byla vypočítána celková přesnost klasifikace cév s touto natrénovanou sítí, která je rovna 53,57 % a celková chybovost klasifikace cév je 46,43 %.

Z normalizované matice záměn klasifikace cév neuronovou sítí s váhami 0,7 pro pozadí, 18 pro tepny a 14 pro žíly, zobrazené na Obr. 6.13 vpravo lze vidět, že pixely pozadí byly úspěšně klasifikovány na 61,8 %, pixely tepen na 27,3 % a pixely žil na 21,8 %. Z matice záměn obsahující četnosti klasifikovaných pixelů byla

vypočítána celková přesnost klasifikace cév s touto natrénovanou sítí, která je rovna 57,90 % a celková chybovost klasifikace cév je 42,10 %.

Z důvodu neuspokojivých výsledných hodnot klasifikací cév byly výsledky na výstupu neuronové sítě vynásobeny se segmentačními maskami cév, čímž vzrostla přesnost klasifikace o více než 20 % u obou natrénovaných sítí. Po vynásobení výsledných obrazů obsahující klasifikované cévy s odpovídajícími segmentačními maskami cév byla celková přesnost klasifikace první neuronové sítě (váhy 0,6 pro pozadí, 17 pro tepny, 14 pro žíly) rovna 81,58 % a celková chybovost klasifikace byla snížena na 18,42 %. Stejný postup s vynásobením výsledných klasifikovaných obrazů se segmentačními maskami cév byl aplikován i u druhé neuronové sítě (váhy 0,7 pro pozadí, 18 pro tepny, 14 pro žíly), přičemž celková přesnost klasifikace vzrostla na hodnotu 81,68 % a celková chybovost klasifikace byla snížena na hodnotu 18,32 %.

Pro srovnání obou natrénovaných sítí jsou jejich výsledné hodnoty klasifikace shrnuty do tabulek. V Tab. 6.2 jsou uvedeny výsledky klasifikace natrénovaných sítí před vynásobením výsledných obrazů se segmentačními maskami a v Tab. 6.3 jsou uvedeny výsledky klasifikace neuronových sítí poté, co byl výsledek klasifikace vynásoben s odpovídající klasifikační maskou.

Tab. 6.2: Shrnutí výsledku klasifikace s využitím neuronových sítí U-Net


	<b>Neuronová síť 1 (váhy 0,6, 17, 14)</b>	<b>Neuronová síť 2 (váhy 0,7, 18, 14)</b>
<b>Celková přesnost [%]</b>	53,57	57,90
<b>Celková chybovost [%]</b>	46,43	42,10

Tab. 6.3: Shrnutí výsledku klasifikace s využitím neuronových sítí, hodnoty po vynásobení klasifikovaných obrazů se segmentačními maskami

	<b>Neuronová síť 1 (váhy 0,6, 17, 14)</b>	<b>Neuronová síť 2 (váhy 0,7, 18, 14)</b>
<b>Celková přesnost [%]</b>	81,58	81,68
<b>Celková chybovost [%]</b>	18,42	18,32

Z tabulek výše lze vidět, že jsou výsledky klasifikace obou sítí po vynásobení klasifikovaných obrazů segmentačními maskami srovnatelné, ač se předtím lišily o 4,33 %. Z toho vyplývá, že pixely pozadí (tedy pixely mimo cévu) sítnice první neuronové sítě byly klasifikovány s vyšší chybovostí.

Z testovací množiny dat byl vybrán jeden snímek a jeho výsledný obraz s klasifikovanými cévami na výstupu první neuronové sítě byl porovnán s výsledným klasifikovaným obrazem na výstupu druhé neuronové sítě (viz Obr. 6.14). Matice záměn odpovídající klasifikovaným obrazům zobrazeným na Obr. 6.14 jsou pak zobrazeny na Obr. 6.15. Přesnost klasifikace cév snímku sítnice první neuronové sítě je 69,05 % a chybovost klasifikace je rovna 30,95 %. Přesnost klasifikace cév snímku druhé neuronové sítě je rovna 74,94 % s chybovostí klasifikace 25,07 %.



Obr. 6.14: Výsledek klasifikace cév na výstupu první neuronové sítě (váhy 0,6 pro pozadí, 17 pro tepny, 14 pro žíly) (vlevo), výsledek klasifikace cév na výstupu druhé neuronové sítě (váhy 0,7 pro pozadí, 18 pro tepny, 14 pro žíly) (uprostřed) a ground truth obraz klasifikovaného snímku (vpravo)


		predikovaná třída		
		pozadí	tepna	žíla
skutečná třída	pozadí	217529	36180	34871
	tepna	9986	2039	1859
	žíla	13421	3503	3172

		predikovaná třída		
		pozadí	tepna	žíla
skutečná třída	pozadí	237555	25476	25549
	tepna	10804	1544	1536
	žíla	15107	2379	2610

Obr. 6.15: Výsledná matice záměn klasifikace cév první neuronové sítě (váhy 0,6 pro pozadí, 17 pro tepny, 14 pro žíly) (vlevo) a druhé neuronové sítě (váhy 0,7 pro pozadí, 18 pro tepny, 14 pro žíly) (vpravo)

Vybraný testovací snímek byl následně vynásoben s odpovídající segmentační maskou cév. Výsledek klasifikace cév násobený s maskou je zobrazen na Obr. 6.16,

kde je opět porovnána výsledná klasifikace cév první a druhé neuronové sítě společně s ground truth obrazem. Matice záměn odpovídající klasifikovaným obrazům zobrazeným na Obr. 6.16 jsou pak zobrazeny na Obr. 6.17. Přesnost klasifikace cév snímku sítnice první neuronové sítě po vynásobení se segmentační maskou je 83,02 % a chybovost klasifikace je rovna 16,98 %. Přesnost klasifikace cév snímku druhé neuronové sítě po vynásobení se segmentační maskou je rovna 83,78 % s chybovostí klasifikace 16,22 %.



Obr. 6.16: Výsledek klasifikace cév na výstupu první neuronové sítě vynásobený se segmentační maskou cév (váhy 0,6 pro pozadí, 17 pro tepny, 14 pro žíly) (vlevo), výsledek klasifikace cév na výstupu druhé neuronové sítě vynásobený se segmentační maskou cév (váhy 0,7 pro pozadí, 18 pro tepny, 14 pro žíly) (uprostřed) a ground truth obraz klasifikovaného snímku (vpravo)


		predikovaná třída		
		pozadí	tepna	žíla
skutečná třída	pozadí	265757	9805	13018
	tepna	12604	527	753
	žíla	17309	1291	1496

		predikovaná třída		
		pozadí	tepna	žíla
skutečná třída	pozadí	268306	8533	11741
	tepna	12682	517	685
	žíla	17640	1035	1421

Obr. 6.17: Výsledné matice záměn klasifikace cév první neuronové sítě (váhy 0,6 pro pozadí, 17 pro tepny, 14 pro žíly) (vlevo) a druhé neuronové sítě (váhy 0,7 pro pozadí, 18 pro tepny, 14 pro žíly) (vpravo) po vynásobení se segmentační maskou cév



Další příklad výsledku klasifikace cév na výstupu první natrénované neuronové sítě s hodnotami vah 0,6 pro pozadí, 17 pro tepny a 14 pro žíly, je zobrazen na Obr. 6.18 vlevo a uprostřed je zobrazen výsledek klasifikace po jeho vynásobení s odpovídající segmentační maskou cév. Oba výsledky klasifikace jsou pak porovnány s ground truth obrazem, který je vykreslen na Obr. 6.18 vpravo.



Obr. 6.18: Výsledek klasifikace cév na výstupu první neuronové sítě (váhy 0,6 pro pozadí, 17 pro tepny, 14 pro žíly) (vlevo), výsledek klasifikace po vynásobení se segmentační maskou cév (uprostřed) a ground truth obraz klasifikovaného snímku (vpravo)


		predikovaná třída		
		pozadí	tepna	žíla
skutečná třída	pozadí	208168	53132	35225
	tepna	6591	2672	2105
	žíla	8963	3334	2370

		predikovaná třída		
		pozadí	tepna	žíla
skutečná třída	pozadí	279495	8026	9004
	tepna	10031	612	725
	žíla	13335	632	880

Obr. 6.19: Výsledná matice záměn klasifikace cév první neuronové sítě (váhy 0,6 pro pozadí, 17 pro tepny, 14 pro žíly) (vlevo) a výsledná matice záměn po vynásobení výsledku klasifikace se segmentační maskou cév (vpravo)

Na Obr. 6.18 vlevo lze vidět, že vysoká chyba klasifikace je převážně způsobena chybně klasifikovanými pixely pozadí, které byly chybně klasifikovány do třídy tepen. Celková přesnost klasifikace byla vyčíslena na hodnotu 66,09 % a celková chyba klasifikace je rovna 33,90 %. Po vynásobení klasifikovaného obrazu se segmentační maskou je již výsledek uspokojivější, přičemž hodnota celkové přesnosti klasifikace vzrostla na hodnotu 87,06 % a chybovost klasifikace klesla na hodnotu 12,94 %.

Příklad výsledku klasifikace cév na výstupu druhé natrénované neuronové sítě s hodnotami vah 0,7 pro pozadí, 18 pro tepny a 14 pro žíly, je zobrazen na Obr. 6.20 vlevo a uprostřed je zobrazen výsledek klasifikace po jeho vynásobení s odpovídající segmentační maskou cév. Oba výsledky klasifikace jsou porovnány s ground truth obrazem, který je vykreslen na Obr. 6.20 vpravo.



Obr. 6.20: Výsledek klasifikace cév na výstupu druhé neuronové sítě (váhy 0,7 pro pozadí, 18 pro tepny, 14 pro žíly) (vlevo), výsledek klasifikace po vynásobení se segmentační maskou cév (uprostřed) a ground truth obraz klasifikovaného snímku (vpravo)

		predikovaná třída		
		pozadí	tepna	žíla
skutečná třída	pozadí	208434	46865	30678
	tepna	8648	4016	2462
	žíla	12313	5753	3391

		predikovaná třída		
		pozadí	tepna	žíla
skutečná třída	pozadí	266953	8439	10585
	tepna	13690	709	727
	žíla	19412	935	1110

Obr. 6.21: Výsledná matice záměn klasifikace cév druhé neuronové sítě (váhy 0,7 pro pozadí, 18 pro tepny, 14 pro žíly) (vlevo) a výsledná matice záměn po vynásobení výsledku klasifikace se segmentační maskou cév (vpravo)

Na Obr. 6.20 vlevo lze pozorovat, že vysoká chyba klasifikace byla opět z velké části zapříčiněna chybně klasifikovanými pixely pozadí. Celková přesnost klasifikace je rovna 66,92 % a celková chybovost klasifikace je rovna hodnotě 33,09 %. Vynásobením klasifikovaného obrazu se segmentační maskou cév vzrostla přesnost klasifikace na hodnotu 83,33 % a celková chybovost klasifikace klesla na 16,68 %.

### 6.3.1 Srovnání klasifikace cév s využitím SVM klasifikátoru a konvoluční neuronové sítě U-Net

Metody klasifikace, které byly navrženy a realizovány v této práci se liší jak svým přístupem klasifikace cév každé z nich, tak dosaženými výsledky klasifikace.

Klasifikace pixelů cév s využitím SVM klasifikátoru probíhala pouze do dvou tříd, pixel byl zařazen do třídy tepna, anebo do třídy žíla. Výsledná klasifikace tak není ovlivněna špatně klasifikovanými pixely pozadí, jako tomu je u klasifikace cév s využitím konvoluční neuronové sítě U-Net. V tomto případě byl každý pixel obrazu klasifikován do jedné ze tří tříd, do třídy pozadí, tepna, či žíla.

Pokud by probíhalo srovnání obou metod s výsledky natrénovaných neuronových sítí, které nebyly vynásobeny se segmentačními maskami, byla by přesnost metody klasifikace s SVM klasifikátorem vyšší. Při srovnání výsledků metod, kdy jsou klasifikovány pouze pixely cév, má naopak vyšší přesnost klasifikace metoda s využitím konvoluční neuronové sítě. V Tab. 6.4 jsou porovnány výsledné hodnoty klasifikace cév s využitím SVM klasifikátoru při klasifikaci celých cév (ne v oblasti zájmu okolo OD) a klasifikace cév natrénovanými neuronovými sítěmi, kdy byly výsledné klasifikované obrazy násobeny se segmentačními maskami.

Tab. 6.4: Shrnutí výsledku klasifikace s využitím SVM klasifikátoru a konvolučních neuronových sítí

	<b>SVM klasifikátor</b>	<b>Neuronová síť 1 (váhy 0,6, 17, 14)</b>	<b>Neuronová síť 2 (váhy 0,7, 18, 14)</b>
<b>Přesnost [%]</b>	63,71	81,58	81,68
<b>Chybovost [%]</b>	36,29	18,42	18,32

## 7 Analýza pulzací cévního řečiště


### 7.1 Použitá data

Data, která byla využita při analýze pulzací cévního řečiště byla získána experimentálním video oftalmoskopem, jehož princip je popsán v podkap. 2.2.


Oční pozadí bylo nasnímano non-mydriatickým video oftalmoskopem s frekvencí 25 snímků za sekundu, se zorným polem  $20^{\circ} \times 15^{\circ}$  a s rozlišením  $1000 \times 700$  pixelů. Snímky jsou šedotónové a jsou centrovány na hlavu optického disku [10].

Součástí nasnímaných videosekvencí sítnice jsou barevné snímky sítnice nasnímané fundus kamerou, segmentační masky segmentovaných retinálních cév a ground truth obrazy s klasifikovanými cévami na tepny a žíly. Součástí sady jsou také souřadnice detekovaných optických disků. Příklad dat je zobrazen na Obr. 7.1 a na Obr. 7.2.

Videosekvence sítnic jsou navzájem lícovány, díky čemuž bylo možné provést výpočet průměrného snímku sítnice. Snímky sítnic z fundus kamery jsou lícovány podle průměrných šedotónových snímků.



Obr. 7.1: Zprůměrovaný snímek z videosekvence získané video oftalmoskopem a odpovídající RGB snímek sítnice nasnímaný fundus kamerou (zleva)



Obr. 7.2: Maska segmentovaných cév a obraz s klasifikovanými cévami (zleva)

## 7.2 Návrh metody pro analýzu pulzací

Analýza rychlých časových změn cév v sítnici umožňuje vyšetření hemodynamických procesů, kdy je sledována např. změna průměru cév v důsledku kolísání krevního tlaku. Také bylo prokázáno, že pulzní parametry průtoku krve v cévním řečišti sítnice jsou ovlivněny výskytem glaukomu. V případě zachycení změn těchto parametrů lze včas diagnostikovat případné patologie a zahájit jejich léčbu [9, 11].


Za účelem analýzy pulzací cévního řečiště byla navržena metoda sestávající z následujících kroků. Po načtení videosekvencí sítnice je potřeba v každé sekvenci definovat oblast zájmu okolo optického disku, ve které proběhne analýza. Ve vymezené oblasti zájmu jsou dále klasifikovány cévy na tepny a žíly, aby bylo možné sledovat změny pulzací v závislosti na druhu cévy. Po úspěšné klasifikaci cév je snímek, resp. jeho oblast zájmu, připravena k analýze pulzací cévního řečiště.

Algoritmy metody pro analýzu pulzací cévního řečiště byly zpracovány v programovacím prostředí Matlab R2020b.

## 7.3 Vymezení oblasti zájmu analýzy

Za účelem analýzy pulzací ve vymezené oblasti zájmu okolo optického disku byl ze souřadnic detekovaného OD nalezen jeho střed. Pomocí získaných souřadnic středu OD byla následně vytvořena první kružnice 1,5 násobku průměru optického disku a druhá kružnice 1,8 násobku průměru optického disku. Z těchto dvou kružnic byly vytvořeny masky a jejich rozdílem byla získána kruhová oblast zájmu.

Zaznačené souřadnice detekovaného optického disku s nalezeným středem OD a kruhová oblast zájmu, kde došlo k analýze pulzací, je zobrazena na Obr. 7.3.




Obr. 7.3: Střed optického disku a kruhová oblast zájmu okolo OD (zleva)


## 7.4 Klasifikace cév

Cévy, které ležely v oblasti zájmu okolo optického disku byly klasifikovány pomocí metody klasifikace cévního řečiště s využitím SVM klasifikátoru z podkap. 5.3. Jediná modifikace této metody spočívala v tom, že již byl detekován optický disk a byla vymezena oblast zájmu klasifikace.

SVM klasifikátor byl natrénován na trénovací množině sestávající z 20 RGB snímků sítnice, které byly součástí nasnímaných videosekvencí. Následně byl SVM klasifikátor otestován na 4 snímcích. Výsledek klasifikace cév v oblasti zájmu je zobrazen na dvou snímcích na Obr. 7.4 a Obr. 7.5. Na obrázcích nalevo je zobrazen výsledek klasifikace a napravo je pro porovnání zobrazen odpovídající ground truth obraz s označenými cévami. Tepny jsou zobrazeny červenou barvou a žíly barvou modrou.



Obr. 7.4: Výsledek klasifikace cév a odpovídající ground truth obraz (zleva)



Obr. 7.5: Výsledek klasifikace cév a odpovídající ground truth obraz (zleva)

Výsledná matice záměn s jednotlivými četnostmi klasifikovaných pixelů z celé testovací množiny je zobrazena na Obr. 7.6. Správně je klasifikováno 83,81 % pixelů tepen a správně klasifikovaných pixelů žil je 79,44 %. Celková přesnost klasifikace je rovna 82,35 % a chybovost klasifikace je 17,65 %.

		<b>predikovaná třída</b>	
		<b>tepna</b>	<b>žila</b>
<b>skutečná třída</b>	<b>tepna</b>	19688	3802
	<b>žila</b>	2445	9449

Obr. 7.6: Matice záměn pro klasifikaci cév


Výsledek klasifikace je mírně zkreslen z důvodu zahrnutí neoznačených cév z ground truth dat do výsledku. Neoznačenou cévu, která je reprezentována růžovou barvou lze vidět na Obr. 7.5 vpravo na ground truth obraze.

## 7.5 Analýza pulzací cév

Po klasifikaci cév sítnice ve zvolené oblasti zájmu okolo optického disku byly z úseků jednotlivých cév získány hodnoty průměrných intenzit pixelů, které byly uloženy do vektoru pro každý snímek z videosekvence.

Jednotlivé úseky cévy byly následně označeny pomocnou numerickou hodnotou s využitím funkce vislabels [46], kdy přiřazená numerická hodnota cévy sloužila pro její identifikaci a pro její přiřazení k příslušné hodnotě průměrné intenzity pixelů. Označení cév numerickou hodnotou je znázorněno na Obr. 7.7. Na závěr již byla vybrána požadovaná céva, u které došlo k analýze pulzací.

Pulzace cév byly vykresleny v podobě signálu, ve kterém lze sledovat jejich měnící se intenzitu pixelů cév. Signál patřící tepně je vykreslen červenou barvou a signál vykreslený barvou modrou reprezentuje žílu. Signály cév, které jsou vykresleny v jednom grafu, byly vybrány ze stejné videosekvence.




Obr. 7.7: Přiřazení numerické hodnoty úsekům cév

### Porovnání signálu tepny a žíly


Pro porovnání průměrných intenzit tepen a žil navzájem byla nalezena maxima a minima průměrné intenzity pixelů získaných signálů a z těchto hodnot byl vypočítán rozdíl. Rozdíly všech maxim a minim byly následně zprůměrovány.

Maximální a minimální hodnoty průměrné intenzity pixelů byly nalezeny s využitím obálky signálu. Některé hodnoty však musely být označeny ručně díky přítomnosti rušivých odlehlých hodnot v signálech. Hodnoty průměrných intenzit pixelů žíly jsou zobrazeny na Obr. 7.8 a nalezená obálka těchto hodnot je zobrazena na Obr. 7.9.




Obr. 7.8: Průměrné intenzity pixelů žíly






Obr. 7.9: Obálka průměrných intenzit pixelů žíly

První vybraný signál tepny a signál žíly je zobrazen na Obr. 7.10. Již na první pohled lze signály od sebe odlišit, jelikož má tepna vyšší průměrnou intenzitu pixelů. Vypočítaná průměrná hodnota rozdílu detekovaných maxim a minim signálu tepny je 0,014 a pro žílu je tato hodnota rovna 0,009.




Obr. 7.10: Porovnání průměrných intenzit pixelů tepny a žíly 1

Druhý vybraný signál tepny a žíly je zobrazen na Obr. 7.11, kde lze také s jistotou rozeznat, který signál patří které cévě. Tepna má vyšší průměrnou intenzitu pixelů a je u ní znatelnější měnící se intenzita pixelů reprezentující pulzace. Vypočítaná průměrná hodnota rozdílu detekovaných maxim a minim signálu tepny je 0,023 a pro žílu je tato hodnota rovna 0,007.



Obr. 7.11: Porovnání průměrných intenzit pixelů tepny a žíly 2

Poslední vybraný signál pro porovnání tepny a žíly je zobrazen na Obr. 7.12. Ze signálů je patrné, že změna průměrných intenzit pixelů je znatelná u obou druhů cév, intenzita pixelů je však u tepny vyšší. Vypočítaná průměrná hodnota rozdílu detekovaných maxim a minim signálu tepny je 0,015 a pro žílu je tato hodnota rovna 0,017.




Obr. 7.12: Porovnání průměrných intenzit pixelů tepny a žíly 3


### Porovnání cév na temporální a nazální straně sítnice

Při pozorování změn průměrné intenzity pixelů mezi cévami bylo zjištěno, že poloha cévy má vliv na výslednou intenzitu pixelů. Většina cév, které ležely na temporální straně sítnice měly průměrnou intenzitu pixelů vyšší, než céva stejného typu ležící na nazální straně sítnice.

Na Obr. 7.13 je znázorněn signál průměrné intenzity pixelů tepen, přičemž tepna ležící na temporální straně sítnice je vykreslena zelenou barvou a tepna ležící na nazální straně sítnice je vykreslena barvou červenou. Následně je na Obr. 7.14 znázorněn signál průměrné intenzity pixelů žil, přičemž žíla ležící na temporální straně sítnice je vykreslena zelenou barvou a žíla ležící na nazální straně sítnice je vykreslena barvou modrou.



Obr. 7.13: Porovnání průměrných intenzit pixelů tepny na temporální a nazální straně sítnice



Obr. 7.14: Porovnání průměrných intenzit pixelů žíly na temporální a nazální straně sítnice

# Závěr

Diplomová práce se zabývá klasifikací arteriálního a žilního řečiště v obrazových datech sítnice. Cílem práce bylo seznámit se s problematikou klasifikace retinálních cév, navrhnout metodu pro klasifikaci cév a realizovat ji v programovém prostředí Matlab. Na základě literární rešerše byly navrženy a realizovány dvě metody klasifikace cév, přičemž první z metod byla založena na použití SVM klasifikátoru a druhá metoda klasifikovala cévy pomocí konvoluční neuronové sítě U-Net. Na závěr práce byla provedena analýza pulzací cévního řečiště v předem definované oblasti zájmu.

První část práce byla věnována anatomii lidského oka se zaměřením na sítnici a její cévní zásobení. Dále byl uveden princip fundus kamery a experimentálního video oftalmoskopu.

V další teoretické části práce byla vypracována literární rešerše odborných publikací, které se zabývají klasifikací retinálních cév. Na základě prostudovaných publikací byly navrženy metody pro účely této práce.

Na závěr teoretické části práce byly popsány metody strojového učení se zaměřením na metodu podpůrných vektorů a konvoluční neuronové sítě.

V praktické části práce byly popsány použité databáze snímků sítnice využitých pro klasifikaci retinálních cév a návrh a realizace vybraných metod klasifikace cévního řečiště ve snímcích očního pozadí. V této části práce byl představen návrh metody klasifikace cév s využitím SVM klasifikátoru, kde byl uveden popis předzpracování snímků sítnice, způsob detekce optického disku a vymezení oblasti zájmu ve snímku, ve které probíhala samotná klasifikace cév. Pro klasifikaci bylo potřeba z cév v oblasti zájmu extrahovat jejich příznaky, které byly využity pro trénování klasifikátoru SVM. Následoval návrh a realizace metody klasifikace cévního řečiště s využitím konvoluční neuronové sítě U-Net, kde byly uvedeny trénovací parametry sítě s jednotlivými průběhy trénování.

Výsledky klasifikace cév byly vyhodnoceny pomocí matice záměn. Klasifikace cév v oblasti zájmu okolo optického disku s využitím SVM klasifikátoru dosahovala celkové přesnosti 68,75 % a celková chybovost klasifikace byla rovna 31,25 %. Natrénovaný klasifikátor SVM byl následně využit pro klasifikaci cév v celém snímku sítnice a v tomto případě dosahovala klasifikace cév celkové přesnosti 63,71 % a celkové chybovosti 36,29 %. Metoda s využitím SVM klasifikátoru správně klasifikovala především velké cévy, avšak selhávala při klasifikaci malých cév a cév ležících v periferii sítnice. Možné vylepšení této metody za účelem vyšší přesnosti klasifikace by spočívalo v extrahování jiných příznaků, které by lépe rozlišovaly jednotlivé druhy cév.

Za účelem klasifikace cév s využitím konvoluční neuronové sítě U-Net byly natrénovány dvě sítě s různými hodnotami vah pro klasifikační třídy. Klasifikace cév pomocí první natrénované sítě, s hodnotami vah 0,6 pro pozadí, 17 pro tepny a 14 pro žíly, dosahovala celkové přesnosti 53,57 % a celková chybovost klasifikace byla rovna 46,43 %. Klasifikace cév s využitím druhé natrénované sítě, s hodnotami vah 0,7 pro pozadí, 18 pro tepny a 14 pro žíly, dosahovala celkové přesnosti 57,90 % a hodnota celkové chybovosti klasifikace byla rovna 42,10 %. Z důvodu neuspokojivých výsledků a faktu, že došlo především k chybné klasifikaci pixelů pozadí, byly obrazy s klasifikovanými cévami na výstupu obou natrénovaných neuronových sítí vynásobeny s odpovídajícími segmentačními maskami cév. Po této úpravě byla celková přesnost klasifikace první neuronové sítě (váhy – 0,6 pro pozadí, 17 pro tepny a 14 pro žíly) rovna 81,58 % a hodnota celkové chybovosti klasifikace se snížila na hodnotu 18,42 %. Celková přesnost klasifikace druhé neuronové sítě (váhy – 0,7 pro pozadí, 18 pro tepny a 14 pro žíly) vzrostla na hodnotu 81,68 % s celkovou chybovostí sítě 18,32 %. Metoda klasifikace cév s využitím neuronové sítě U-Net selhávala především při klasifikaci malých cév.

Možné vylepšení klasifikace s využitím sítě U-Net za účelem vyšší přesnosti by spočívalo buď v nastavení jiných vah pro klasifikační třídy, anebo v použití jiných trénovacích algoritmů a parametrů. Sít by mohla být lépe naučena v případě, že by trénovací množina obsahovala více dat jen jedné databáze, čehož lze docílit umělým navýšením trénovací množiny (např. rozdělením snímků trénovací a testovací množiny na několik malých překrývajících se částí, přičemž by musel být testovací snímek na výstupu sítě rekonstruován z takto překrývajících se částí obrazů), anebo nalezením databáze, která obsahuje více dat.

Poslední část práce byla věnována analýze pulzací cévního řečiště. V této části byly zpracovávány videosekvence očního pozadí získané experimentálním video oftalmoskopem, přičemž byla nejprve definována oblast zájmu ve snímcích sítnice a cévy v této oblasti zájmu byly klasifikovány metodou s využitím SVM klasifikátoru. Klasifikace cév zde dosahovala přesnosti 82,35 % a hodnota chybovosti klasifikace byla rovna 17,65 %. Klasifikované cévy byly následně zpracovány do podoby signálů a byla sledována měnící se průměrná intenzita pixelů cév. Pozorované rozdíly v signálech jednotlivých cév by mohly být dále využity jako příznaky při klasifikaci cévního řečiště na tepny a žíly.

# Literatura

- [1] SYNEK, Svatopluk a Šárka SKORKOVSKÁ. *Fyziologie oka a vidění*. 2., dopl. a přeprac. vyd. Praha: Grada, 2014. ISBN 978-80-247-3992-2.
- [2] HOLIBKOVÁ, Alžběta a Stanislav LAICHMAN. *Přehled anatomie člověka*. 5. vyd. Olomouc: Univerzita Palackého v Olomouci, 2010. ISBN 9788024426150.
- [3] Basic Anatomy And Physiology Of The Human Visual System (Eye Anatomy). In: *Medical anatomical knowledge center* [online]. Dostupné z: <http://imedicalcenter.blogspot.com/2015/06/basic-anatomy-and-physiology-of-human.html>
- [4] KUČHYNKA, Pavel. *Oční lékařství*. Praha: Grada, 2007. ISBN 978-80-247-1163-8.
- [5] MIRI, Maliheh, Zahra AMINI, Hossein RABBANI a Raheleh KAFIEH. A Comprehensive Study of Retinal Vessel Classification Methods in Fundus Images. *Journal of medical signals and sensors* [online]. 2017, 7(2), 59-70.
- [6] KONDERMANN, Claudia, Daniel KONDERMANN a Michelle YAN. Blood Vessel Classification into Arteries and Veins in Retinal Images. *Proceedings of SPIE* [online]. 2007. DOI: 10.1117/12.708469.
- [7] HEITMAR, Rebekka, Angelos A. KALITZEOS, Sunni R. PATEL, Diana PRABHU-DAS a Robert P. CUBBIDGE. Comparison of subjective and objective methods to determine the retinal arterio-venous ratio using fundus photography. *Journal of Optometry* [online]. 2015, 8(4), 252-257. ISSN 18884296. DOI: 10.1016/j.optom.2014.07.002
- [8] BENEŠ, Pavel. *Přístroje pro optometrii a oftalmologii*. Brno: Národní centrum ošetrovatelství a nelékařských zdravotnických oborů, 2015. ISBN 978-80-7013-577-8.
- [9] TORNOW, Ralf-Peter, Jan ODSTRČILIK a Radim KOLAR. Time-resolved quantitative inter-eye comparison of cardiac cycle-induced blood volume changes in the human retina. *Biomedical Optics Express* [online]. 2018, 9(12). ISSN 2156-7085. DOI: 10.1364/BOE.9.006237.
- [10] KOLAR, Radim, Ralf. P. TORNOW, Jan ODSTRČILIK a Ivana LIBEROVÁ. Registration of retinal sequences from new video-ophthalmoscopic camera. *BioMedical Engineering OnLine* [online]. 2016, 15(1). ISSN 1475-925X. DOI: 10.1186/s12938-016-0191-0.

- [11] TORNOW, Ralf-Peter, Radim KOLAR a Jan ODSTRCILIK. Video ophthalmoscope measures fast temporal changes in the human retina. *SPIE Newsroom* [online]. 2015. ISSN 18182259. DOI: 10.1117/2.1201509.006061.
- [12] MARTINEZ-PEREZ, M.E., A.D. HIGHER, A.V. STANTON, S.A. THORN, N. CHAPMAN, A.A. BHARATH a K.H. PARKER. Retinal vascular tree morphology: a semi-automatic quantification. *IEEE Transactions on Biomedical Engineering* [online]. 2002, 49(8), 912-917. ISSN 0018-9294. DOI: 10.1109/T-BME.2002.800789.
- [13] GRISAN, E. a A. RUGGERI. A divide et impera strategy for automatic classification of retinal vessels into arteries and veins. *Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (IEEE Cat. No.03CH37439)* [online]. IEEE, 2003, s. 890-893. ISBN 0-7803-7789-3. DOI: 10.1109/IEMBS.2003.1279908.
- [14] NIEMEIJER, Meindert, Nico KARSSEMEIJER, Maryellen L. GIGER, Bram VAN GINNEKEN a Michael D. ABRAMOFF. Automatic classification of retinal vessels into arteries and veins. *Proceedings of SPIE - The International Society for Optical Engineering* [online]. 2009-2-26. DOI: 10.1117/12.813826.
- [15] MIRSHARIF, G., F. TAJERIPOUR, F. SOBHANMANESH, H. POURREZA a T. BANAEI. Developing an automatic method for separation of arteries from veins in retinal images. *1st International eConference on Computer and Knowledge Engineering (ICCKE)* [online]. IEEE, 2011, s. 202-207. ISBN 978-1-4673-5713-5. DOI: 10.1109/ICCKE.2011.6413351.
- [16] DASHTBOZORG, Behdad, Ana Maria MENDONCA a Aurelio CAMPILHO. An Automatic Graph-Based Approach for Artery/Vein Classification in Retinal Images. *IEEE Transactions on Image Processing* [online]. 2014, 23(3), 1073-1083. ISSN 1057-7149. DOI: 10.1109/TIP.2013.2263809.
- [17] HAMEDNEJAD, Golnoush a Hossein POURGHASSEM. Retinal blood vessel classification based on color and directional features in fundus images. *22nd Iranian Conference on Biomedical Engineering (ICBME)* [online]. IEEE, 2015, s. 257-262. ISBN 978-1-4673-9351-5. DOI: 10.1109/ICBME.2015.7404152.
- [18] AYUB, Lubna, Abdul samad KHAN, Javeria AYUB, Sara AYUB, Usman AKRAM, Samra IRSHAD a Imran BASIT. Differentiation of blood vessels in retina into arteries and veins using neural network. *International Conference on Computing, Electronic and Electrical Engineering (ICE Cube)*



- [online]. IEEE, 2016, s. 301-306. ISBN 978-1-5090-1252-7. DOI: 10.1109/I-CECUBE.2016.7495242.
- [19] MEYER, Maria Ines, Adrian GALDRAN, Pedro COSTA, Ana Maria MENDONÇA a Aurélio CAMPILHO. Deep Convolutional Artery/Vein Classification of Retinal Vessels. CAMPILHO, Aurélio, Fakhri KARRAY a Bart TER HAAR ROMENY, ed. *Image Analysis and Recognition* [online]. Cham: Springer International Publishing, 2018, 2018-06-06, s. 622-630. Lecture Notes in Computer Science. ISBN 978-3-319-92999-6. DOI: 10.1007/978-3-319-93000-8\_71.
- [20] HUANG, Fan, Behdad DASHTBOZORG, Tao TAN a Bart M. TER HAAR ROMENY. Retinal artery/vein classification using genetic-search feature selection. *Computer Methods and Programs in Biomedicine* [online]. 2018, 161, 197-207. ISSN 01692607. DOI: 10.1016/j.cmpb.2018.04.016.
- [21] YIN, Xiao-Xia, Samra IRSHAD a Yanchun ZHANG. Artery/vein classification of retinal vessels using classifiers fusion. *Health Information Science and Systems* [online]. 2019, 7(1). ISSN 2047-2501. DOI: 10.1007/s13755-019-0090-4.
- [22] REMESEIRO, Beatriz, Ana Maria MENDONÇA a Aurélio CAMPILHO. Automatic classification of retinal blood vessels based on multilevel thresholding and graph propagation. *The Visual Computer* [online]. 2020. ISSN 0178-2789. DOI: 10.1007/s00371-020-01863-z.
- [23] RAJ, P. Kevin, Aniketh MANJUNATH, J. R. Harish KUMAR a Chandra Sekhar SEELAMANTULA. Automatic Classification of Artery/Vein from Single Wavelength Fundus Images. In: *2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI)* [online]. IEEE, 2020, s. 1262-1265. ISBN 978-1-5386-9330-8. DOI: 10.1109/ISBI45749.2020.9098580.
- [24] HONZÍK, Petr. *Strojové učení*. Elektronická skripta VUT Brno, 2006.
- [25] GOODFELLOW, Ian, Yoshua BENGIO a Aaron COURVILLE. *Deep learning*. Cambridge, MA: MIT press, 2016. Adaptive computation and machine learning series. ISBN 0262035618.
- [26] BURGESS, Christopher J.C. A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery* [online]. 1998, 2(2), 121-167. ISSN 13845810. DOI: 10.1023/A:1009715923555.
- [27] SHMILOVICI, Armin. Support Vector Machines. MAIMON, Oded a Lior ROKACH, ed. *Data Mining and Knowledge Discovery Handbook* [online]. Boston, MA: Springer US, 2010, 2009-7-7, s. 231-247. ISBN 978-0-387-09822-7. DOI: 10.1007/978-0-387-09823-4\_12.

- [28] VONDRÁK, Ivo. *Neuronové sítě*. Elektronická skripta VŠB - Technická univerzita Ostrava, 2009.
- [29] LECUN, Yann, Yoshua BENGIO a Geoffrey HINTON. Deep learning. *Nature* [online]. 2015, 521(7553), 436-444. ISSN 0028-0836. DOI: 10.1038/nature14539.
- [30] SAMER, Hijazi, Kumar RISHI a Rowen CHRIS. *Using Convolutional Neural Networks for Image Recognition*. 2015.
- [31] RONNEBERGER, Olaf, Philipp FISCHER a Thomas BROX. U-Net: Convolutional Networks for Biomedical Image Segmentation. NAVAB, Nassir, Joachim HORNEGGER, William M. WELLS a Alejandro F. FRANGI, ed. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* [online]. Cham: Springer International Publishing, 2015, 2015-11-18, s. 234-241. Lecture Notes in Computer Science. ISBN 978-3-319-24573-7. DOI: 10.1007/978-3-319-24574-4\_28.
- [32] HU, Qiao, Michael D. ABRÀMOFF a Mona K. GARVIN. Automated Separation of Binary Overlapping Trees in Low-Contrast Color Retinal Images. SALINESI, Camille, Moira C. NORRIE a Óscar PASTOR, ed. *Advanced Information Systems Engineering* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013, s. 436-443. Lecture Notes in Computer Science. ISBN 978-3-642-38708-1. DOI: 10.1007/978-3-642-40763-5\_54.
- [33] DRIVE: Digital Retinal Images for Vessel Extraction. *Grand Challenge* [online]. Dostupné z: <https://drive.grand-challenge.org/DRIVE/>
- [34] IOSTAR – Retinal Vessel Segmentation and Artery/Vein Classification Dataset. *RetinaCheck* [online]. Dostupné z: <http://www.retinacheck.org/datasets>
- [35] ZHANG, Jiong, Behdad DASHTBOZORG, Erik BEKKERS, Josien P. W. PLUIM, Remco DITS a Bart M. TER HAAR ROMENY. Robust Retinal Vessel Segmentation via Locally Adaptive Derivative Frames in Orientation Scores. *IEEE Transactions on Medical Imaging* [online]. 2016, 35(12), 2631-2644. ISSN 0278-0062. DOI: 10.1109/TMI.2016.2587062.
- [36] ABBASI-SURESHJANI, Samaneh, Iris SMIT-OCKELOEN, Jiong ZHANG a Bart TER HAAR ROMENY. Biologically-Inspired Supervised Vasculature Segmentation in SLO Retinal Fundus Images. KAMEL, Mohamed a Aurélio CAMPILHO, ed. *Image Analysis and Recognition* [online]. Cham: Springer International Publishing, 2015, 2015-7-4, s. 325-334. Lecture Notes in Computer Science. ISBN 978-3-319-20800-8. DOI: 10.1007/978-3-319-20801-5\_35.

- [37] Data on Fundus Images for Vessels Segmentation, Detection of Hypertensive Retinopathy, Diabetic Retinopathy and Papilledema. *Mendeley Data* [online]. Dostupné z: <https://data.mendeley.com/datasets/3csr652p9y/2>
- [38] AKRAM, Muhammad Usman, Shahzad AKBAR, Taimur HASSAN, Sajid Gul KHAWAJA, Ubaidullah YASIN a Imran BASIT. Data on fundus images for vessels segmentation, detection of hypertensive retinopathy, diabetic retinopathy and papilledema. *Data in Brief* [online]. 2020, 29. ISSN 23523409. DOI: 10.1016/j.dib.2020.105282.
- [39] ŠRÁMEK, Jaromír, Ondřej RÁČEK, Martin SEDLÁŘ a Vojtěch MORNSTEIN. *Získávání a analýza obrazové informace*. Učební text LF MU, 2011. Dostupné z: <http://www.med.muni.cz/biofyz/Image/ucebnice.pdf>
- [40] MIKOLAJCZYK, Agnieszka a Michal GROCHOWSKI. Data augmentation for improving deep learning in image classification problem. In: *2018 International Interdisciplinary PhD Workshop (IIPHDW)* [online]. IEEE, 2018, 2018, s. 117-122. ISBN 978-1-5386-6143-7. DOI: 10.1109/IIPHDW.2018.8388338.
- [41] YI, Dokkyun, Jaehyun AHN a Sangmin JI. An Effective Optimization Method for Machine Learning Based on ADAM. *Applied Sciences* [online]. 2020, 10(3). ISSN 2076-3417. DOI: 10.3390/app10031073.
- [42] A Gentle Introduction to Cross-Entropy for Machine Learning. *Machine Learning Mastery* [online]. Dostupné z: <https://machinelearningmastery.com/cross-entropy-for-machine-learning/>
- [43] Understanding Categorical Cross-Entropy Loss, Binary Cross-Entropy Loss, Softmax Loss, Logistic Loss, Focal Loss and all those confusing names. *Raúl Gómez blog* [online]. Dostupné z: [https://gombru.github.io/2018/05/23/cross\\_entropy\\_loss/](https://gombru.github.io/2018/05/23/cross_entropy_loss/)
- [44] KINGMA, Diederik P.; BA, Jimmy. *Adam: A method for stochastic optimization*. arXiv: 1412.6980, 2014.
- [45] Confusion Matrix. *Data Science and Machine Learning* [online]. Dostupné z: <https://manisha-sirsat.blogspot.com/2019/04/confusion-matrix.html>
- [46] Steve Eddins, 2021. Visualize output of BWLABEL (<https://www.mathworks.com/matlabcentral/fileexchange/19665-visualize-output-of-bwlabel>), MATLAB Central File Exchange.

## Seznam symbolů, veličin a zkratek

<b>ADAM</b>	adaptivní výpočet momentu (z angl. Adaptive Moment Estimation)
<b>AFIO</b>	Armed Forces Institute of Ophthalmology
<b>AVR</b>	arterio-venózní poměr (z angl. Arterio-Venous Ratio)
<b>CNN</b>	konvoluční neuronová síť (z angl. Convolutional Neural Network)
<b>GLCM</b>	koincidenční matice stupňů šedi (GLCM, z angl. Gray Level Co-occurrence Matrix)
<b>kNN</b>	k-nejbližší soused (z angl. k-Nearest Neighbor)
<b>LDA</b>	lineární diskriminační analýza (z angl. Linear Discriminant Classifier)
<b>MLP</b>	vícevrstvá perceptronová vrstva (z angl. Multi-Layer Perceptron)
<b>OD</b>	optický disk
<b>PCA</b>	analýza hlavních komponent (z angl. Principal Components Analysis)
<b>QDA</b>	kvadratická diskriminační analýzy (z angl. Quadratic Discriminant Classifier)
<b>ROC</b>	z angl. Receiver Operating Characteristic
<b>SLO</b>	skenovací laserová oftalmoskopie (z angl. Scanning Laser Ophthalmoscopy)
<b>SVM</b>	metoda podpůrných vektorů (z angl. Support Vector Machines)

# A Přílohy

Odevzdané přílohy obsahují zdrojové kódy, které byly vypracovány v rámci praktické části diplomové práce.

Skripty a funkce byly vytvořeny v programovacím prostředí Matlab R2020b a neuronová síť U-Net byla trénována v programovacím prostředí Matlab R2019b pomocí GPU NVIDIA GeForce GTX 1060 6 GB využívající CUDA architekturu.

Z důvodu omezené velikosti odevzdávací práce nebyly do přílohy zahrnuty modely natrénovaných SVM klasifikátorů a natrénovaných neuronových sítí U-Net.

```
/ ..... kořenový adresář
├── README.txt
├── analiza_pulzaci ..... skripty pro analýzu pulzací
│   ├── extrakce_priznaku_video.m ..... extrakce příznaků pro SVM klasifikaci
│   ├── pulzace.m ..... zpracování videosekvence
│   ├── SVM_klasifikace_video.m ..... SVM klasifikace cévního řečiště
│   ├── vid3_test_average.tif ..... příklad zprůměrovaného snímku
│   ├── vid3_test_class.png ..... příklad ground truth snímku
│   ├── vid3_test_img.png ..... příklad snímku z fundus kamery
│   ├── vid3_est_maskOD.mat ..... detekované body optického disku
│   ├── vid3_test_seg.tif ..... segmentační maska cév
│   └── vislabels.m ..... funkce pro vizualizaci výsledku bwlabels
├── SVM_klasifikace_cevniho_reciste ..... skripty pro klasifikaci pomocí SVM
│   ├── extrakce_priznaku.m ..... extrakce příznaků cév z celé sítnice
│   ├── extrakce_priznaku_maska.m ..... extrakce příznaků cév z oblasti zájmu
│   ├── normalizace_priznaku.m ..... normalizace příznaků
│   ├── rite01_test_class.png ..... příklad ground truth obrazu
│   ├── rite01_test_img.tif ..... příklad fundus snímku
│   ├── rite01_test_mask.mat ..... maska oblasti zájmu
│   ├── rite01_test_seg.png ..... příklad segmentační masky cév
│   ├── ROI.m ..... detekce OD a vymezení oblasti zájmu
│   └── SVM_klasifikace.m ..... SVM klasifikátor
├── UNET_klasifikace_cevniho_reciste... skripty pro klasifikaci pomocí sítě U-Net
│   ├── 06_test_class.tif ..... příklad ground truth snímku
│   ├── 06_test_seg.tif ..... příklad segmentační masky cév
│   ├── data_unet.m ..... příprava dat
│   ├── pixelLabel_06.png ..... příklad výsledku sítě U-Net
│   ├── unet.m ..... trénování a testování sítě
│   └── vysledek_unet.m ..... vyhodnocení a vizualizace výsledků
├── afio_priprava_dat.m ..... skript pro úpravu snímků AFIO databáze
├── labels_afio.m ..... skript pro zakódování ground truth obrazů
├── labels_iostar.m ..... skript pro zakódování ground truth obrazů
├── labels_rite.m ..... skript pro zakódování ground truth obrazů
├── labels_video.m ..... skript pro zakódování ground truth obrazů
└── vizualizace.m ..... skript pro převod matice tříd na RGB obraz
```